

Universidad de San Andrés

Escuela de Negocios

Maestría en Gestión de Servicios Tecnológicos y de Telecomunicaciones

Análisis de la implementación de Machine Learning en el diagnóstico por imágenes

Autor: Alejo Ezequiel Leivi

DNI: 29.503.147

Mentor de Tesis: Alejandro Prince

Victoria, Buenos Aires, 22 de Julio de 2019



Tesis de Graduación

MAESTRÍA EN GESTIÓN DE SERVICIOS TECNOLÓGICOS Y DE TELECOMUNICACIONES

ANÁLISIS DE LA IMPLEMENTACIÓN DE MACHINE LEARNING EN EL DIAGNÓSTICO POR IMÁGENES

Por:

Alejo Ezequiel Leivi

Mentor:

Alejandro Prince

Victoria, Provincia de Buenos Aires, 22 de julio de 2019

RESUMEN

El siglo XX se ha caracterizado por avances tecnológicos, los cuales han generado un aumento paulatino en la esperanza de vida de las personas. Esta mejora trae asociada una serie de problemas para la industria de la salud. La misma se enfrenta a un escenario en el que cada vez más pacientes requieren una mayor cantidad de estudios y una mejor calidad de atención. En contraposición, la cantidad de profesionales médicos no aumenta en una proporción que acompañe la demanda. Dentro de las especialidades médicas, se encuentra el caso del Diagnóstico por Imágenes. Sólo tomando en cuenta a Estados Unidos, la cantidad de estudios que se han realizado durante 2018 es de aproximadamente los 800 millones, mientras que la cantidad de especialistas no supera los 31.000. Esto haría que cada médico tuviera por informar, solo para ese año, aproximadamente 25.000 estudios.

En los albores de la Cuarta Revolución Industrial, la Inteligencia Artificial posee el potencial de volver a definir, en mayor o menos medida, a la industria de la salud en general y al Diagnóstico por Imágenes en particular, brindando la posibilidad de dar un salto exponencial en eficacia y eficiencia. Dentro de la Inteligencia Artificial, gracias a sus avances en el reconocimiento de imágenes, Machine Learning comienza a ser la respuesta de las empresas tecnológicas para dar soporte a los prestadores de salud, y a sus médicos. Este trabajo tiene por objetivo realizar un análisis de los principales beneficios y barreras asociados a la implementación de Machine Learning en el Diagnóstico por Imágenes poniendo un especial foco en la eficacia y eficiencia obtenida, los aspectos éticos, regulatorios y el impacto en el rol del médico especialista y en el ecosistema de *startups*.

Palabras clave: salud, medicina, radiología, diagnóstico por imágenes, tecnología, inteligencia artificial, machine learning, deep learning.

AGRADECIMIENTOS

A Melany, por acompañarme permanentemente y alentarme en cada objetivo que me propongo. Por ayudarme a encontrar los espacios necesarios para poder realizar este trabajo.

A Julieta, mi fuente inagotable de energía.

A Alejandro Prince, por aceptar dirigir esta tesis. Por ser guía, por su paciencia, conocimiento, consejo y amistad.

A Hernán Yervoni, por colaborar desde el primer momento con este trabajo, aportando una visión siempre enriquecedora.

A Gabriel Przybylski, por sus consejos y colaboración, por ser mi compañero de estudio durante la carrera de grado y la maestría, por su amistad.

A Luis López, por brindarme su tiempo para conversar acerca del enfoque de este trabajo, por proponer ideas que solo mejoraron el resultado final, por su amistad.

A todos los profesionales entrevistados, por recibirme, brindarme su tiempo, conocimiento y experiencia.

A la Universidad Tecnológica Nacional y a la Universidad de San Andrés, pilares en mi continua formación profesional.

ÍNDICE

QUAERERE VERUM
Universidad de
SanAndrés

CAPÍTULO 1 - PRESENTACIÓN

1.1 Introducción y justificación

Los avances tecnológicos que se han dado, sobre todo desde el siglo XX, protagonizados por mejoras en salud e higiene, vacunas y antibióticos, han generado un marcado descenso de la mortalidad del ser humano, desde la edad infantil hasta la adultez. Esto ha sido el factor fundamental para el aumento de la esperanza de vida (Garrido, 2009).

En el siglo XXI, este proceso se verá profundizado. Se estima que la cantidad de personas mayores, es decir, aquellas de 60 años o más, se duplique para 2050 y triplique para 2100, pasando 962 millones en 2017 a 3100 millones en 2100. A nivel mundial, la población adulta crece significativamente más rápido que la población joven (United Nations, 2017). Esta tendencia provoca un marcado envejecimiento de la población, factor que está a punto de convertirse en una de las transformaciones más significativas del siglo XXI. Esto generará consecuencias en todos los sectores de la sociedad, incluyendo el mercado laboral, financiero y la demanda de bienes y servicios (United Nations, 2017). Una gran parte de estos servicios estaría vinculados a la demanda de salud. Por otro lado, Estados Unidos tiene proyectado que, en 2020 y 2025, habrá descensos de entre 91.500 y 130.600 profesionales médicos respectivamente (Rosenkrantz, Hughes, & Duszak, 2015). Un sistema en donde cada vez habrá mayor demanda de atención de pacientes y a la par una proyección de descenso en la oferta de profesionales médicos, requerirá la búsqueda de alternativas para evitar un inevitable colapso.

La Inteligencia Artificial (en adelante, IA) es la ciencia e ingeniería para la fabricación de máquinas inteligentes, especialmente programas informáticos inteligentes (Mccarthy, 2007). La misma surge como una de las respuestas al problema descripto. A través de la misma, se puede generar un impacto enorme en todos los actores tradicionales del sistema de salud (laboratorios, prestadores, seguros,

fabricantes de soluciones médicas y pacientes) como así también en el nuevo actor de este mercado (empresas de tecnología), generando ahorros significativos de dinero y tiempo (Aboshiha, Gallagher, & Gargan, 2019). Sin embargo, el uso de IA en salud trae aparejado una serie de problemas a resolver. Potenciales pérdidas de empleo, responsabilidad en la toma de decisiones, protección de datos personales del paciente, son algunos de los desafíos que el avance de esta tecnología conlleva. Existen diferentes tipos de IA. Machine Learning (en adelante, ML) es uno de los más importanes a los fines de este trabajo. ML es el proceso a través del cual las computadoras son programadas para optimizar un criterio de *performance* utilizando datos de ejemplo o experiencia del pasado (Alpaydin, 2014).

Nuestro trabajo estará enfocado en la tecnología de ML y en su subtipo, el Deep Learning (en adelante, DL), el cual posee una arquitectura que lo hace particularmente bueno para clasificar imágenes. DL encuentra un interesante momento para ser usado, dado: el gran volumen de datos en salud, los avances en las unidades de procesamiento gráfico (GPU) y la baja de costos en la ejecución de los modelos (Erickson et al., 2018).

El Diagnóstico por Imágenes (en adelante, DPI) es una especialidad médica que, valiéndose de distintos tipos de tecnologías (rayos X, campos magnéticos y ultrasonido, entre las más utilizdas), produce imágenes médicas, las cuales son utilizadas por el médico especialista para detectar, diagnosticar y tratar enfermedades. El Dr. Ricardo García Mónaco considera que el DPI ha nacido como una especialidad innovadora. Su historia fue marcada por la implementación de tecnologías que permitieron alcanzar el mayor potencial dentro de su época. La IA no será la excepción (R. García Mónaco, comunicación personal, 27 de mayo de 2019).

El proceso de atención de un paciente en el área de DPI se caracteriza por el siguiente flujo de trabajo: solicitud de turno, obtención de imágenes, análisis de imágenes, informe, plan de tratamiento y seguimiento (Harris, 2018b). En este trabajo pondremos especial foco en la etapa de análisis de imágenes.

Los médicos especialistas en DPI consumen un tercio de su tiempo informando imágenes (IBM, 2018). Bajo este escenario, en la década del 80, han surgido las *Computer-Aided Detection and Diagnosis* (en adelante CAD). Las CAD son un tipo de sistema informático utilizado como complemento al profesional en la detección y diagnóstico de enfermedades. Las mismas llegaron a alcanzar masividad en algunos casos, como la mamografía. Pero dado que no han generado beneficios respecto a la precisión y al ahorro de tiempos, las mismas fueron dejadas de lado (Oakden-Rayner, 2019).

El uso de ML y DL brinda a las CAD una nueva oportunidad. Algunos expertos en IA han especulado que estos sistemas basados en ML pronto podrán superar a los médicos en ciertas tareas de interpretación de imágenes (Chartrand et al., 2017). Esto conlleva a dos corrientes. La primera tiende a pensar que el DPI terminará como una especialidad próspera para los profesionales (Chockley & Emanuel, 2016). La otra, considera que en lugar de reemplazar a los médicos, la posibilidad más probable, es que éstos asimilen los beneficios de las nuevas herramientas, mejorando así la calidad y la eficiencia de su trabajo (Thrall et al., 2018). Estos puntos abren la pregunta acerca de cómo se modificará la labor diaria del especialista en DPI, y cuáles son sus perspectivas a largo plazo.

Inversores públicos y privados parecieran comprender las oportunidades que existen en el sector de la salud y cómo la IA puede revolucionarlo. Se espera que en 2021, las inversiones de ambos sectores supere los $6,6 billones[1] de dólares (Forbes, 2019b). Por otro lado, se estima que en el 2026, las aplicaciones de IA en salud generarán, sólo en Estados Unidos, un ahorro anual de $150 billones de dólares (Collier, Fu, Yin, & Christiansen, 2017).

[1] Alineados a la mayor parte de la bibliografía utilizada en todo nuestro trabajo, la cifra billón hace referencia a un millardo o mil millones (1.000.000.000).

Son más de 100 *startups* las que se encuentran incursionando en soluciones de análisis de imágenes basadas en ML (Harris, 2019). Grandes empresas como IBM, Google y Microsoft, a través de investigaciones propias y de acuerdos con terceros, se unirían a dichos emprendimientos por la lucha de la conquista del mercado. Dado que nos encontramos en una etapa de gran cantidad de investigaciones y pocas implementaciones en clientes, se desconoce cuántas de estas empresas subsistirán. Pero ciertamente serán aquellas que demuestren su habilidad para entregar el máximo valor en términos de relevancia clínica, validación clínica, integración con flujos de trabajo ya existentes y mejor retorno de la inversión (Harris, 2018b).

1.2 Problemática

Según la Organización Mundial de la Salud (en adelante, OMS), el 80% de las decisiones médicas en el mundo desarrollado se toman con el apoyo de estudios de imágenes (Madrid, 2013). Por otro lado, en 2015, solamente en Estados Unidos, se han realizado 800 millones de exámenes de imágenes (IBM, 2018). Dichos exámenes generaron aproximadamente 60 billones de imágenes médicas. Estas serían cantidades imposibles de procesar en tiempo y forma, teniendo en cuenta que la cantidad de médicos especialistas en DPI es de 31.000. Si se quisieran analizar todas las imágenes, cada médico debería ver una cada dos segundos de trabajo, durante todas sus jornadas laborales (IBM, 2016).

Es por este motivo que se requiere implementar soluciones que garanticen al sistema de salud su sustentabilidad. Si bien la IA presenta muchos beneficios para el análisis de imágenes médicas, hay aspectos importantes que se deberían tener en cuenta.

El Dr. Daniel Luna considera que se ha llegado a una etapa importante de la IA en la industria de la salud. Pero no es algo que se va a dar de un momento para otro, sino que será un proceso que llevará un largo tiempo. El mismo no dependerá exclusivamente de los avances tecnológicos. “Todo el camino de transición en el uso de la IA se va a dar como un proceso de transformación. No es un cambio, es

una transformación. Y esa transformación no es tecnológica. Es la medicina la que tiene que transformar" El Dr. Daniel Luna agrega, además, que para que la IA en salud comience un camino de crecimiento sostenido, para así alcanzar el uso masivo, deberá pasar por una etapa más de enfriamiento. "Por otro lado, la IA ya tuvo dos inviernos y dos primaveras. Ahora estamos transitando la tercera primavera. Y ya llegará un nuevo invierno, el cual estará caracterizado por una reacción social ante la desconfianza en su uso y el temor de que millones de personas pasen a ser inútiles" (D. Luna comunicación personal, 24 de mayo de 2019).

Por último, la Dra. Margaret Chan, ex Directora General de la OMS, advierte que "la IA es una nueva frontera para el sector de la salud… El potencial de la IA en la atención sanitaria es enorme, pero también lo es la necesidad de tomar algunas precauciones" (Kos, 2018). Son esas precauciones las que podrían definir el avance de ML en el DPI. Entre los temas más importantes podemos mencionar los siguientes:

- **Regulación**. Cada país o región posee una autoridad competente. Sin el aval de dichas autoridades, los servicios de ML no pueden ser comercializados. Por ejemplo, en Estados Unidos, para que una solución pueda salir al mercado, debe ser aprobada por la *Food and Drug Administration* (en adelante, FDA). En el caso de Argentina, debe ser aproada por la Administración Nacional de Medicamentos, Alimentos y Tecnología Médica (ANMAT).
- **Confidencialidad**. Es necesario aplicar técnicas de anonimización sobre los estudios de pacientes utilizados para llevar a cabo las soluciones de ML.
- **Responsabilidad legal**. Un diagnóstico incorrecto basado en una solución de ML genera una pregunta clave: quién es el responsable de dicha falla. Una pregunta no tan trivial de responder, teniendo en cuenta que habría involucradas distintas partes, entre los que se pueden destacar, la empresa desarrolladora de software, el prestador de salud y el médico.

- **Caja negra**. Los algoritmos de ML utilizadas para el análisis de imágenes no permiten determinar la manera en la que se ha arribado a una decisión, de manera que no se puede garantizar que las mismas no incurran en sesgos.
- **Impacto en el rol del médico**. Cómo se verá afectada el puesto de trabajo del especialista en DPI es un factor clave en la adopción de esta nueva tecnología, dado que es éste el principal usuario de la misma.
- **Economía**. Es necesario poder demostrar que las soluciones de IA generarán un beneficio económico para los actores involucrados de manera tal que justifique su inversión (GE, 2018).

1.3 Preguntas de investigación

- ¿Puede Machine Learning mejorar la precisión de resultados a la par de reducir los tiempos en Diagnóstico por Imágenes?

- ¿Se encuentra en riesgo, a corto y mediano plazo, la continudad laboral de los médicos especialistas a partir de la implementación de Machine Learning en Diagnóstico por Imágenes?

- ¿Existe una industria impulsando soluciones de Machine Learning en Diagnóstico por Imágenes?

1.4 Objetivos

Objetivo Principal

- Determinar beneficios y barreras que expliquen el estado actual de ML aplicado al DPI.

Objetivos Secundarios

- Investigar los conceptos de IA, ML y DL.

- Reconocer los actores de los sistemas de salud, la transferencia de valor que supone la implementación de IA y de qué formas puede ser implementada.
- Analizar el accionar que están teniendo las grandes empresas, como Google, Apple, Microsoft, Facebook, Amazon e IBM, respecto a la IA.
- Definir al Diagnóstico por Imágenes y los sistemas para la detección y el diagnóstico de enfermedades.
- Caracterizar la Cuarta Revolución Industrial y su impacto en el trabajo
- Describir los casos de uso de ML en Diagnóstico por Imágenes.
- Analizar cuáles son las oportunidades para el desarrollo de ML en Diagnóstico por Imágenes.
- Identificar los aspectos éticos y regulatorios involucrados en la implementación de ML en Diagnóstico por Imágenes.
- Caracterizar la industria de ML en Diagnóstico por Imágenes.

1.5 Metodología

El trabajo llevado a cabo estará principalmente caracterizado por una metodología de tipo exploratoria.

Teniendo en cuenta el bajo grado de madurez que posee el tema estudiado, hemos optado por este tipo de metodología ya que resulta la más adecuada cuando el objetivo es examinar un tema o problema de investigación poco estudiado o que no ha sido abordado antes (Hernandez Sampierí et. al, 1997).

En referencia a los trabajos exploratorios, Dankhe (1986) agrega que, generalmente, no son un fin en sí mismo, sino que "…por lo general determinan tendencias, identifican relaciones potenciales entre variables y establecen el “tono” de investigaciones posteriores más rigurosas". Justamente, en este trabajo estamos analizando el uso de ML para el DPI, que, si bien, viene siendo estudiado desde una perspectiva médica-científica para casos puntuales, es muy escasa desde un punto de vista de management, limitándose a reportes de fuentes no académicas.

Teniendo en cuenta esta situación, con el objetivo de reducir el sesgo de nuestra investigación, haremos uso de la triangulación entre fuentes de información. La misma es un recurso muy útil dado que nos permite realizar una aproximación al objeto de estudio mediante distintos métodos, contrastándolos y complementándolos (Denzin, 1989).

El paradigma de nuestro trabajo será cualtitativo, y como tal, pondremos en práctica algunos de sus métodos, como son el análisis de fuentes primarias y secundarias, entrevistas en profundidad y la observación (Cook & Reichardt, 1986). En relación a la documentación, analizaremos principalmente publicaciones científicas, informes de consultoras, libros y revistas especializdas en la materia. En relación a la observación, presenciaremos la actividad de médicos especialistas en DPI para comprender su función y cómo las soluciones de ML podrían incorporarse a su modalidad de trabajo. Por otro lado, realizaremos una serie de entrevistas semiestructuradas a referentes argentinos del DPI, la ciencia, la IA, ML y el emprendedurismo.

Asimismo, Orozco (1996) define la investigación cualitativa como un proceso, una construcción que en el tiempo se va superando, a la cual el investigador accede mediante interpretaciones sucesivas sobre el objeto indagado; es decir, se conoce en progreso y no de una sola vez. En sintonia, este trabajo estará basado en un trabajo de campo iterativo e incremental, muy útil ya que nos encontramos investigando un tema novedoso en el mercado. Partiendo del análisis documental, nos enfocaremos luego en la realización de las entrevistas. Las mismas generan un circulo virtuoso a partir de posibilitar una mayor comprensión de la documentación leída previamente, y a su vez el enriquecimiento de las preguntas a realizar en las siguientes entrevistas.

Dentro de la recolección y análisis, tanto de fuentes primarias y secundarias, se destacan:

- Artículos científicos y publicaciones en medios especializados cuyo tema principal sea IA, ML, DL y DPI.
- Publicaciones de entidades especializadas en salud y trabajo, como ser la OMS, el Foro Económico Mundial y la Organización de las Naciones Unidas.
- Publicaciones de entidades regulatorias, como la FDA y el Grupo Europeo sobre la Ética de la Ciencia y las Nuevas Tecnologías.
- Informes de reconocidas consultoras que analizan el mercado de ML en salud en general y DPI en particular, entre las que se destacan PWC, Accenture, BCG, Gartner, IBM y Signify Research.
- Libros que nos ayuden a caracterizar el rol de la IA en la Cuarta Revolución Industrial, el impacto de la implementación de IA en los puestos de trabajo, y el impacto de la IA y ML en salud.
- Publicaciones de revistas especializadas en negocios y tecnología, como *Forbes, Harvard Business Review, Business Insider, TechCrunch*; y de salud, como Healthcare Weekkly y The Medical Futurist.
- Tesis de grado y posgrado en donde se describe IA y ML.

Universidad de SanAndrés

En relación a las entrevistas semiestructuradas se realizarán entrevistas a los siguientes referentes:

- Dr. Facundo Manes, médico neurólogo especialista neurociencias y la sociedad basada en el conocimiento.
- Dr. Diego Slezak y el Dr. Tomás Crivelli, ambos doctorados en IA y emprendedores de ML en DPI.
- Dr. Ricardo García Mónaco, jefe de DPI del Hospital Italiano de Buenos Aires.
- Dr. Gustavo Pantol, médico especialista en DPI.
- Dr. Daniel Luna, jefe de informática médica del Hospital Italiano de Buenos Aires.
- Dr. Federico Milano, Ing. Hernán Borré, Ing. Carlos Selmo, Dr. Enzo Ferrante especialistas en IA, ML y análisis de imágenes.

Por último, otra fuente de información es la asistencia al evento *Forbes Healthcare Summit 2019* en donde se trataron temas vinculados a los desafíos y oportunidades de la industria de salud en Argentina, haciendo especial foco en medicina de precisión.



CAPÍTULO 2 - MARCO TEÓRICO

A continuación, definiremos y clasificaremos IA. Haremos un breve recorrido por su historia, destacando sus hitos más importantes. Dentro de IA, si bien haremos un repaso de la técnica de Visión Aritficial, nos focalizaremos en ML y en su subtipo, DL. Luego, detallaremos cuáles son los aspectos éticos a tener en cuenta. Realizaremos, además, una descripción de la Cuarta Revolución Industrial y de cómo se cree que la IA puede impactar en la economía y en el trabajo.

Dimensionaremos el mércado y el impacto de la democratización de la IA. Detallaremos en qué etapas del proceso sanitario la IA puede aportar valor y cómo puede transferirse el mismo, entre los actores del sistema, en función de sus inversiones. Haremos un análisis del accionar para alcanzar el mercado de IA en salud de Google, IBM, Apple, Facebook, Microsoft y Amazon.

Por último, describiremos el DPI, haciendo un repaso por sus inicios. Detallaremos las modalidades más utilizadas y las tecnologías que la caracterizan.

QUAERERE VERUM
Universidad de
SanAndrés

2.1 Inteligencia Artificial

2.1.1 Qué es la Inteligencia Artificial

Previo a definir qué es la IA, comenzaremos haciendo una aproximación al término inteligencia.

La palabra inteligencia proviene del latín intelligere, un término que está compuesto por *inter* (entre) y *legere* (leer o escoger) (Wikipedia, 2019). Por lo tanto, *Intellegere* significa elegir entre varias cosas.

El Dr. Facundo Manes define a la inteligencia como la flexibilidad para resolver una tarea de manera original y creativa (F. Manes, comunicación personal, 29 de mayo de 2019).

Por otra parte, en el libro Surviving IA (Chace, 2015) se define a la inteligencia como la habilidad que posee un agente en alcanzar objetivos en un amplio espectro de

ambientes. Similar es la definición del libro, Vida 3.0. En el mismo se la define como la capacidad de alcanzar objetivos complejos, como por ejemplo, aspectos referidos a la comprensión, autocrítica, resolución de problemas o el auto aprendizaje (Max Tegmark, 2017).
Por su parte, el psicólogo estadounidense Howard Gardner define nueve tipos de inteligencia: lingüística, lógica-matemática, musical, espacial, corporal, interpersonal, intrapersonal, existencial, naturalista (Gardner, 1983).

A través de las diferentes definiciones, de algo podemos estar seguros y es de que no existe un consenso acerca de qué es la inteligencia o el ser inteligente.

Si bien el científico inglés Alan Turing[2] fue uno de los precursores en comenzar a trabajar con temas vinculados a la IA, preguntándose si las máquinas podían pensar, fue recién en 1956, cuando el científico estadounidense John McCarthy[3] define el concepto de IA. McCarthy la define como la ciencia e ingeniería para la fabricación de máquinas inteligentes, especialmente programas informáticos inteligentes (McCarthy, 2007). Por su parte, el científico estadounidense Marvin Minsky, la define como la ciencia de hacer que las máquinas hagan cosas que requerirían inteligencia si fueran hechas por hombres (Guinovart, 1998).

En el libro Inteligencia Artificial y Computación Avanzada (Romero, 2007) se realizan dos tipos de definiciones, una desde el punto de vista ingenieril y otra desde el científico. Desde el primero, se define a la IA como la creación de sistemas informáticos que realicen tareas para las cuales se precise algún tipo de inteligencia. Por otro lado, desde el punto de vista científico, la IA se puede definir como el estudio del comportamiento inteligente, siendo su fin conseguir una teoría de la inteligencia que explica la conducta que se produce en seres de naturaleza

2. Para más información: https://www.turing.org.uk/publications/dnb.html
3. Para más información: http://jmc.stanford.edu/

inteligente, y que guíe la creación de entes artificiales capaces de alcanzar dicho proceder inteligente.

A los exponentes de IA les gusta hablar de máquinas inteligentes pero hay muy poco acuerdo acerca de qué es exactamente inteligente (Schank, 2010).

Sí pareciera haber un acuerdo acerca de la capacidad transformadora de la IA. Andrew Ng[4] la define como la nueva electricidad, por su capacidad de transformar todas las industrias, de la misma manera que lo hizo la electricidad hace cien años (Ng, 2019).

Finalmente, la pregunta sobre qué es la IA se trata de que, posiblemente, tenga múltiples respuestas. Depende fuertemente de los objetivos de los investigadores involucrados, y cualquier definición de IA es dependiente de los métodos que se emplean en contruir modelos de IA. Por último, es una cuestión de resultados. Estos problemas acerca de su definición existen precisamente porque el desarrollo de la IA no ha sido completado (Schank, 2010).

A continuación, haremos un repaso por los principales hitos de la IA.

2.1.2 Historia

El hombre, en los comienzos de su evolución, ya había comenzado a buscar diferentes medios que le permitan disminuir su esfuerzo en el trabajo. En los comienzos, hace dos millones de años, con la invención de las armas y las primeras herramientas. Luego, hace al menos, setecientos mil años, aprende a controlar el fuego. Diez mil años atrás aprende acerca de agricultura y ganadería, esta última como herramienta para trabajar la tierra con un menor esfuerzo. Un cuarto hito que detalla se dio hace cinco mil años, y es la invención de la escritura. A partir de la misma el hombre empieza a contar con la posibilidad de almacenar información fuera de su cerebro, llevándola a papel, pergaminos y más tarde a libros (Alfonseca,

4. Para más información: https://www.andrewng.org/

2019). Más cercano en el tiempo, hace doscientos años, se da comienzo a la Revolución Industrial. Desde el siglo XVIII y XIX y primera mitad del siglo XX, el hombre reemplaza a los animales de arado por maquinarias, las cuales eran impulsadas por nuevas fuentes de energía (térmica, eléctrica, química, entre otras). En la segunda mitad del siglo XX, aparecen nuevas máquinas, las computadoras. A diferencia de las maquinarias de la Revolución Industrial, las computadoras llegan como sustituto y complemento de las actividades mentales del hombre. Cálculos complejos, tareas repetitivas, son las primeras actividades que se delegan a las computadoras. Tal vez su contra radica en su rigidez. Cada escenario que no haya sido contemplado por el hombre previamente será un escenario en donde la computadora no podrá acompañarlo (Alfonseca, 2019).

En 1943, los científicos estadounidenses Warren McCulloch[5] y Walter Pitts[6] presentaron su modelo de neuronas artificiales, considerado el primer trabajo del campo de IA, aun cuando todavía no existía el término. Para esto se basaron en tres fuentes: conocimiento de la fisiología básica y función de las neuronas del cerebro humano, un análisis formal de la lógica proposicional y la teoría de la computación de Turing (Russell, 1994).

En la década del cuarenta, durante la segunda guerra mundial, Alan Turing desarrolla, exitosamente, una máquina llamaba Bombe[7]. La misma tenía el objetivo de desencriptar los mensajes elaborados por Engima, máquina utilizada por el ejército alemán para enviar información de manera segura. Se considera a Bomb como una de los desarrollos fundacionales de ML (Shaan Ray, 2018).

En 1950, Alan Turing publica el artículo “Computer Machinery and Intelligence”, pieza clave para la IA. En el mismo realiza la pregunta clave, “¿Pueden las máquinas pensar?”. En el artículo, Turing también desarrolla la idea del Test de

5. Para más información: https://en.wikipedia.org/wiki/Warren_Sturgis_McCulloch

6. Para más información: https://en.wikipedia.org/wiki/Walter_Pitts

7. Para más información: http://www.rutherfordjournal.org/article030108.html

Turing, más conocido como Test de la Imitación[8] (McGuire, Smith, Huang, & Yang, 2006).

Pero fue en al año 1956 que, John McCarthy, miembro del Grupo de Dartmouth[9] (del cual pertenecían Marvin Minsky, Arthur Samuel[10], Oliver Selfdrige[11], entre otros) propone construir máquinas que no se limiten a realizar cálculos sino también a realizar operaciones que sean consideradas inteligentes. Dicho grupo se animó a estimar que en 10 años habría programas capaces de traducir entre dos idiomas y de jugar al ajedrez y vencer al campeón del mundo (Alfonseca, 2019).

Otro de los integrantes del Grupo de Dartmouth era Arthur Samuel, perteneciente a la empresa IBM, quien desarrollo, también en 1956, un programa para jugar a las damas y aprender de las experiencias de cada partida. Luego utilizaría el conocimiento adquirido en futuras partidas. En pocos años el programa fue capaz de vencer a su desarrollador y hacer muy buenos desempeños en campeonatos. Esto sería una aproximación a los objetivos propuestos por el Grupo de Dartmouth, aunque todavía se encontraban lejos ya que la complejidad del ajedrez es mucho mayor al de las damas (Alfonseca, 2019).

A fines de la década del 50, Alex Bernstein, también de la empresa IBM, desarrolló un programa con las capacidades de jugar al ajedrez como un principiante. Pero la predicción de ganarle al campeón del mundo no se cumplió hasta 1997, en donde Deep Blue, programa fabricado por IBM, consigue vencer al campeón del mundo de ese momento, Garry Kasparov, en un torneo de 6 partidas. Tampoco fue acertada la predicción acerca de la traducción entre dos idiomas, problema en el cual se deben enfrentar a dos lenguas naturales, plagadas de ambigüedades e irregularidades con pocas coincidencias entre sí. Al día de hoy, habiendo pasado por diferentes procedimientos, este trabajo sigue perfeccionándose a través de actores como Google (Alfonseca, 2019).

8. Para más información: https://courses.cs.washington.edu/courses/csep590/06au/projects/history-ai.pdf

9. Para más información: http://inteligenciaartificial1il131.blogspot.com/

10. Para más información: https://history-computer.com/ModernComputer/thinkers/Samuel.html

11. Para más información: https://en.wikipedia.org/wiki/Oliver_Selfridge

El error en las predicciones del Grupo Dartmouth se profundiza en 1969, año en el que Marvin Minsky y Saymour Papert demostraron matemáticamente que las redes neuronales artificiales de una o dos capas (perceptrones con capa oculta) con las que se trabajó durante toda la década del 50, no fueron capaces de realizar una función booleana como el "o exclusivo"[12]. Esta función sí se podía resolver con una red de tres capas. El problema se encontraba que las computadoras de aquella época no tenían la velocidad ni la memoria para procesar ese tipo de redes partidas (Alfonseca, 2019).

En la década del setenta, aparecen los Sistemas Expertos y con ellos una ola de optimismo en el desarrollo de la IA. Es Japón, a finales de década, el país que impulsa el proyecto Quinta Generación[13], cuyo objetivo era desarrollar en diez años máquinas con las capacidades de pensar de un ser humano, de comunicarse en japonés y de traducir en forma perfecta entre los idiomas inglés y japonés. A principios de la década del noventa el proyecto fue cancelado ya que no se consiguieron los resultados propuestos (McGuire et al., 2006). Con la, ya mencionada, victoria de Deep Blue contra Kasparov finalmente se alcanza una de las metas propuestas por McCarthy. En 2017, Deepmind AlphaGo, proyecto encabezado por Google ha vencido, en una serie de tres partidas, al campeón del mundo de Go, Ke Jie (Broussard, 2018).

2.1.3 Clasificación

La IA se clasifica en dos tipos:

- **Inteligencia Artificial Débil** (en inglés, Artificial Narrow Intelligence, ANI): es en donde la computadora emula un estado de inteligencia, pero realmente no piensa.

12. Para más información: https://es.wikipedia.org/wiki/Puerta_XOR

13. Para más información: https://www.nytimes.com/1992/06/05/business/fifth-generation-became-japan-s-lost-generation.html

- **Inteligencia Artificial General** (en inglés, Artificial General Intelligence, AGI): es aquella que incluye a las hipotéticas máquinas cuya inteligencia es comparable o superior a la humana (Alfonseca 2019).

La principal diferencia entre IA Débil y IA General radica en los objetivos que se establecen para cada una. Mientras que una IA Débil está limitada en cumplir con lo que nosotros pedimos, una IA General tiene la capacidad de reflexionar sobre sus objetivos y decidir si debe ajustarlos de forma autónoma (Chace, 2015).

Existe un debate en el mundo sobre si la IA General será una realidad en algún momento del tiempo o si siempre existirá como un concepto teórico o de ciencia ficción.

Asociado a esto, se pronunció el Dr. Diego Slasek. “Quien está haciendo una revolución es la empresa DeepMind. Hace un año, aproximadamente, lanzaron un video del que considero es un antes y un después. En el video se ve como enseñaron a un robot virtual (no era físico, sino simulado) a caminar. El robot, que tiene articulaciones iguales a las humanas, fue puesto en el piso y la función de costo definida era que intente caminar. El robot comienza a moverse azarosamente, se desarma, va intentando nuevas estrategias, hasta que, pasado el tiempo, aprende a caminar. Luego, se analizaron los recorridos del tipo de movimiento, desde que está tirado en el piso hasta que camina. Y encontraron que gran parte de los movimientos que aparecieron eran los mismos que realizaban los bebés, después los chicos y luego los adultos. Si bien eso no es IA General, es una aproximación. En el juego del Go[14], la computadora de DeepMind le ganó al campeón del mundo[15]. La misma basó sus estrategias en el aprendizaje de una gran cantidad de partidas entre humanos. Seis meses después de ese hito, DeepMind lanza Alpha Zero, que es la misma computadora que le ganó al campeón

14. Para más información: https://en.wikipedia.org/wiki/Go_(game)

15. Para más información: https://www.bbc.com/news/technology-40042581

de Go, pero que no aprende con partidas jugadas por humanos, sino que va aprendiendo a través de partidas realizadas por ella misma. Es decir, aprende desde cero. Solo recibe las reglas del juego. Luego, se analizaron qué estrategias de juego aprendió en el camino y se encontraron estrategias que ningún ser humano había utilizado antes. Ahí también están empezando a aparecer algunas ideas de IA General" (D. Slezak, comunicación personal, 28 de mayo de 2019).

El Dr. Tomás Crivelli considera que el estado del arte de la IA no permite pensar seriamente en una IA General. "Tenemos mucho camino todavía por delante con la IA Débil y son incontables las aplicaciones. Y me parece que si bien es importante saber hacia dónde vamos, no considero que el estado del arte ni el mundo esté en condiciones de discutir seriamente la IA General. Sería hacer sólo predicciones" (T. Crivelli, comunicación personal, 13 de junio de 2019).

2.1.4 Principios éticos

Bostrom & Yudkowsky (2011) plantean en el artículo "Las éticas de la inteligencia artificial", cinco características que deben tener los sistemas basados en IA:

- Responsabilidad. Cuando un sistema falla, ¿de quién es la responsabilidad?
- Transparencia. Será cada vez más importantes desarrollar algoritmos de IA transparentes a su inspección.
- Auditabilidad. Si el algoritmo de ML está basado, por ejemplo, en Redes Neuronales (concepto desarrollado en el punto 2.2.2) complicadas, será casi imposible entender por qué, o cómo, el algoritmo está tomando determinadas decisiones. Por otro lado, si el aprendizaje de la máquina está basado en árboles de decisión, es más transparente para el desarrollador.
- Incorruptibilidad. Debe ser robusto contra la manipulación.
- Predictibilidad. Los programas deben ser escritos sabiendo cuáles deberían ser sus comportamientos posibles.

Existen otros problemas, relacionados a cómo afecta la implementación de IA en la vida diaria de las personas, que es necesario conocer. Así, a partir de los mismos, poder realizar una evaluación moral acerca de la conveniencia de su implementación, en qué sectores realizar la transformación, y cuáles conservar de la manera en que hoy los conocemos (Pascual, 2018) Algunos ejemplos son:

- Desempleo. Existen diferentes posiciones acerca de cómo se verá afectado el trabajo con los avances de la IA. Existen posiciones que van desde la creencia de una destrucción significativa del empleo a posiciones más moderadas en donde se sugiere que los puestos de trabajo irán cambiando a la par de que se crearán nuevas posiciones. Profundizaremos este tema, más adelante en este mismo capítulo.
- Tecno adicción. Existe una dependencia cada vez mayor de gran parte de la sociedad respecto al rol de la tecnología. Comprender el correcto uso de la misma no es una tarea sencilla. Para esto se debe formar a las personas, fomentando un equilibrio entre las que podemos llamar vida analógica y vida digital.
- Seguridad. Este concepto hace referencia a tomar los recaudos necesarios para que la tecnología no atente contra el derecho a la vida, la integridad física y la moral (Pascual, 2018).
- Afectación a los derechos fundamentales y humanos. Ampliaremos este punto con la visión que posee el Grupo Europeo sobre Ética de las ciencias y las Nuevas Tecnologías, más adelante en esta sección.

QUAERERE VERUM
Universidad de SanAndrés

En 2017, el *Future of Life Institute* (ubicado en Massachusetts, Estados Unidos) realizó un encuentro en Asilomar, en el cual participaron líderes e investigadores en economía, leyes, ética y filosofía. En la misma se definieron veintitrés principios fundamentales para que la IA impacte en forma positiva en la vida de la sociedad entera. La lista detallada es la siguiente:

- Problemas de investigación

- Metas de investigación. El objetivo debe ser realizada con un objetivo específico que conlleve finalmente un beneficio para la sociedad.
- Inversión en investigación. La financiación de la investigación de IA debe realizarse sobre proyectos que aseguren su uso beneficioso.
- Conexión entre ciencia y política. Debe haber un intercambio constructivo y saludable entre los investigadores de IA y los encargados de legislar su uso.
- Cultura de investigación. Una cultura de cooperación, confianza y transparencia debe ser construida entre investigadores y desarrolladores de IA.
- Evitar la carrera. Los equipos encargados de desarrollar sistemas con IA deben cooperar activamente y que su competencia quede supeditada a garantizar cuestiones fundamentales como las omisiones en estándares de seguridad.

- Ética y Valores
  - Seguridad. Los sistemas basados en IA deben ser seguros durante todo su ciclo de vida como así también verificables.
  - Transparencia en los fallos. Si un sistema basado en IA genera algún tipo de daño, en necesario saber el por qué del mismo.
  - Transparencia judicial. La participación en la toma de decisiones de un sistema autónomo debe darse siempre que se pueda proporcionar una explicación auditable por una autoridad humana competente.
  - Responsabilidad. Los diseñadores y las empresas desarrolladoras de los sistemas basados en IA son los responsables en las implicancias morales de su uso, mal uso, acciones, con una responsabilidad de modificar las soluciones para estar alineados a esto.
  - Alineación de valores. Los sistemas basados en IA deben ser diseñados de manera tal que sus objetivos y comportamientos estén alineados con los valores humanos.

- Valores humanos. Los sistemas basados en IA deben ser diseñados y operados de manera tal que sean compatibles con la dignidad humana, los derechos, la libertad y la diversidad cultural.
- Privacidad individual. Las personas deben dar su consentimiento para que los sistemas basados en IA accedan, administren y controlen sus datos.
- Libertad y Privacidad. La aplicación de IA a los datos personales no debe restringir la libertad, percibida o real, de los individuos.
- Beneficio compartido. Las tecnologías basadas en IA deben beneficiar a tanta gente como sea posible.
- Prosperidad compartida. La prosperidad económica creada por la IA debe ser compartida ampliamente, en busca del beneficio de toda la humanidad.
- Control humano. Los humanos deben elegir cómo y cuándo delegar las decisiones a los sistemas basados en IA en busca de lograr sus objetivos.
- No subversión. El poder delegado al control de sistemas avanzados basados en IA debe respetarse y mejorarse, y no subvertir los procesos cívicos y sociales de los cuales depende la salud de la sociedad.
- Carrera armamentística basada en IA. Debe ser evitada una carrera armamentística en armas letales autónomas.

* Problemas a largo plazo
  - Precaución acerca de la capacidad de la IA. Al no haber un consenso, se debe evitar los supuestos acerca de los límites de capacidad que puede tener la IA.
  - Importancia. La IA avanzada debe representar un gran cambio en la historia del planeta y se debe planear para poder ser administrada con el cuidado y los recursos adecuados.

- Riesgos. Los riesgos planteados por los sistemas basados en IA, especialmente los de índole catastrófica o existencial, deben ser objeto de planificación y deben realizarse esfuerzos de mitigación adecuados según el impacto esperado.
- Auto mejora recursiva. Los sistemas basados en IA diseñados para poder corregirse o replicarse a sí mismos recursivamente, de manera que pueden incrementar su calidad o su cantidad, deben ser objetos de medidas de seguridad y de un estricto control.
- Bien común. La superinteligencia solo debe ser desarrollada al servicio de una ética amplia y compartida, y por el beneficio de la humanidad, y no así de un país u organización.

Alineado al encuentro de Asilomar, el Grupo Europeo sobre Ética de las ciencias y las Nuevas Tecnologías propone, en su declaración del 2018 sobre "Inteligencia Artificial, robótica y sistemas autónomos" (European Group on Ethics in Science and New Technologies, 2018) ha definido un conjunto de principios éticos fundamentales y prerrequisitos democráticos.

- Dignidad Humana. El respeto al ser humano no deber ser violado por tecnologías autónomas. Esto significa que la toma de decisiones hecha por algoritmos autónomos debe ser regulada. También implica que debe haber límites para evitar que se le haga creer a una persona que está tratando con otra, en vez de con un algoritmo y, en tal caso, poder decidir si asignamos una tarea a un humano o a un algoritmo.
- Autonomía. Toda tecnología autónoma debe respetar la capacidad humana de elegir sí delegar determinadas decisiones o acciones, cuándo y cómo hacerlo. Para eso se requiere que los algoritmos sean transparentes y previsibles, de manera tal que se pueda intervenir cuando se lo considere necesario.

- Responsabilidad. Los sistemas autónomos deben ser diseñados y desarrollados de manera tal que respeten la pluralidad de valores y derechos humanos fundamentales. No deben entrañar riesgos inaceptables para los seres humanos. Esto debe ser guiado por un auténtico interés en la ética de la investigación, en la responsabilidad social de los programadores y en la cooperación académica mundial para proteger derechos y valores humanos fundamentales.
- Justicia, Equidad, Solidaridad: Los sesgos discriminatorios en los conjuntos de datos utilizados para entrenar y ejecutar los sistemas basados en IA deben evitarse. En caso de no ser posible, deben ser detectados, notificados y neutralizados lo antes posible.
- Democracia. La IA no debe poner en peligro a los ciudadanos, despojarlos de derechos o de su individualidad. Tampoco deben inhibir o influir en la toma de decisiones políticas, infringir la libertad de expresión y el derecho a recibir y difundir información sin interferencia.
- Estado de Derecho y rendición de cuentas. Asociado a la protección contra la violación de los derechos humanos por parte de los sistemas autónomos, por ejemplo, la seguridad o la privacidad. Además, los gobiernos y las organizaciones internacionales deben incrementar sus esfuerzos para establecer en quién recae la responsabilidad de los daños causados por el desempeño no deseado de los sistemas autónomos.
- Seguridad, protección, e integridad física y mental. Con el fin de garantizar que estos sistemas no infrinjan el derecho de los seres humanos a la integridad física y mental, y a un entorno seguro, se deben tomar en cuenta las siguientes dimensiones:
  - la seguridad externa, que se ofrece al entorno y a los usuarios.
  - la confiabilidad y la robustez interna, por ejemplo, contra la piratería.
  - la seguridad emocional, que se refiere a la interacción humano-máquina.

- Protección de datos y privacidad. La IA debe respetar las regulaciones de protección de datos. No se deben recopilar o difundir datos, ni ser ejecutados en conjuntos de datos para los que estas actividades no han sido consentidas.
- Los sistemas autónomos no deben interferir en el derecho de la vida privada.
- Sostenibilidad. La IA debe responder a la responsabilidad humana de garantizar la vida en nuestro planeta, la continua prosperidad de la humanidad y la conservación del medioambiente.

A continuación, detallaremos ML, haciendo referencia a su arquitectura de redes neuronales y a su subtipo, el DL. Por útimo haremos un repaso de la técnica de Visión. Por otro lado, en el Anexo C de este trabajo, se podrá encontrar una breve descripción de otros tipos de IA Débil difundidos, como son los sistemas expertos, el procesamiento de lenguaje natural (en adelante, PLN), el reconocimiento de voz y la robótica.

2.2 Machine Learning

2.2.1 Definición de Machine Learning

ML es un tipo de IA que permite a las máquinas aprender en forma directa de ejemplos y de experiencia, la cual es adquirida a partir de un conjunto de datos (conocido como *dataset*), a través de un entrenamiento. La programación tradicional está basada en reglas estáticas, las cuales establecen cómo resolver un problema, paso a paso. Por lo contrario, con ML se dispone una gran cantidad de datos para utilizar como ejemplo de cómo la tarea puede ser realizada, o para detectar patrones (The Royal Society, 2017).

Este tipo de algoritmos tienen la capacidad de predecir nuevos casos en base a la experiencia aprendida a través de los datos que fueron usados para su entrenamiento (Gisela & García, 2014).

2.2.1.1 Tipos de Aprendizaje

Broussard (2018) clasifica a los tipos de aprendizaje en tres tipos:

- **Supervisado**: por cada entrada al sistema se establece la salida esperada. El objetivo es aprender una regla general que establezca relación entre la entrada y la salida. El aprendizaje supervisado puede dividierse en:
    - *Clasificación:* las salidas del sistema son finitas y discretas y son interpretadas como la clase a la que pertenece. Por ejemplo: “0” o “1”; “Falso” o “Verdadero”; “Sí” o “No”.
    - *Regresión*: las salidas son continuas.
- **No Supervisado:** a diferencia del aprendizaje supervisado, para cada entrada no se brinda ningún tipo de salida, por lo que se le deja a este encontrar algún tipo de estructura en la entrada.
- **Reinforcement**: el programa interactúa con un ambiente dinámico en el cual debe realizar un objetivo específico. En este caso, se le brinda al algoritmo premios y castigos, a medida que va transitando el problema. Los premios y castigos son utilizados con el objetivo de que el algoritmo aprenda las consecuencias de sus decisiones.

En relación a esto, el Ing. Carlos Selmo considera que la madurez del aprendizaje supervisado es mayor al del aprendizaje no supervisado. “El desempeño que poseen el aprendizaje no supervisado es muy dependiente del problema, del conocimiento previo que se posee y de qué se desea hacer. En dominios específicos, depende qué se quiera hacer, está funcionando bien. Pero no brilla como el aprendizaje supervisado” (C. Selmo, comunicación personal, 17 de junio de 2019).

Por otro lado, los algoritmos pueden ser entrenados en modo *offline* y *online*. El entrenamiento *offline* es realizado tanto para la fase de entrenamiento como de prueba fuera del ambiente productivo. Luego, los modelos entrenados son

"congelados" antes de ser desplegados en el ambiente productivo. Cualquier modificación que se realice será hecha nuevamente de modo *offline,* probada y nuevamente desplegada en producción. Este método es el más utilizado en ML ya que brinda la oportunidad de la verificación del comportamiento del mismo, previo a que sea utilizado por los usuarios finales (The Royal Society, 2017).

El *dataset* utilizado en la etapa de entrenamiento *offline* puede dividirse en tres sub-sets: set de entrenamiento, set de validación y set de prueba. Cada uno es utilizado con un fin específico.

- ***Set* de entrenamiento**. Utilizado para entrenar y optimizar los parámetros de las Redes Neuronales (descriptas en el punto 2.2.2). El entrenamiento consiste en utilizar el *dataset,* repetidas veces, utilizando el error generado para ajustar los pesos de las neuronas (Chartrand et al., 2017). Se denomina *Epoch* al acto realizar una ejecución entera del *dataset*. Es necesario ejecutar el *dataset* más de una vez ya que al disponer de datos acotados es requerido, con el objetivo de ajustar en la forma más precisa posible, los pesos de la red. Por otro lado, dado que el *dataset* no se ejecuta en su totalidad en una sola vez, suele dividirse en porciones denominadas *batches*. A su vez, cada ejecución de un batch representa una iteración (Sharma, 2017).
- ***Set* de validación**. Utilizado para evaluar un modelo de manera frecuente. Es decir, ya habiendo sido pasada una etapa de entrenamiento, es posible correr este set con el único objetivo de ajustar los parámetros de la red. Es importante destactar que el algoritmo no aprende en esta etapa. Solo lo hace con el set de entrenamiento (Shah, 2017).
- ***Set* de prueba.** Utilizado, una vez que todos los parámetros del modelo fueron fijados. Este set es utilizado al final del estudio para generar el reporte final de precisión del modelo (Chartrand et al., 2017).

En el entrenamiento *online* el algoritmo también es entrenado y probado de manera *offline*, pero una vez desplegado en el ambiente de producción continúa el aprendizaje con los datos reales (The Royal Society, 2017).

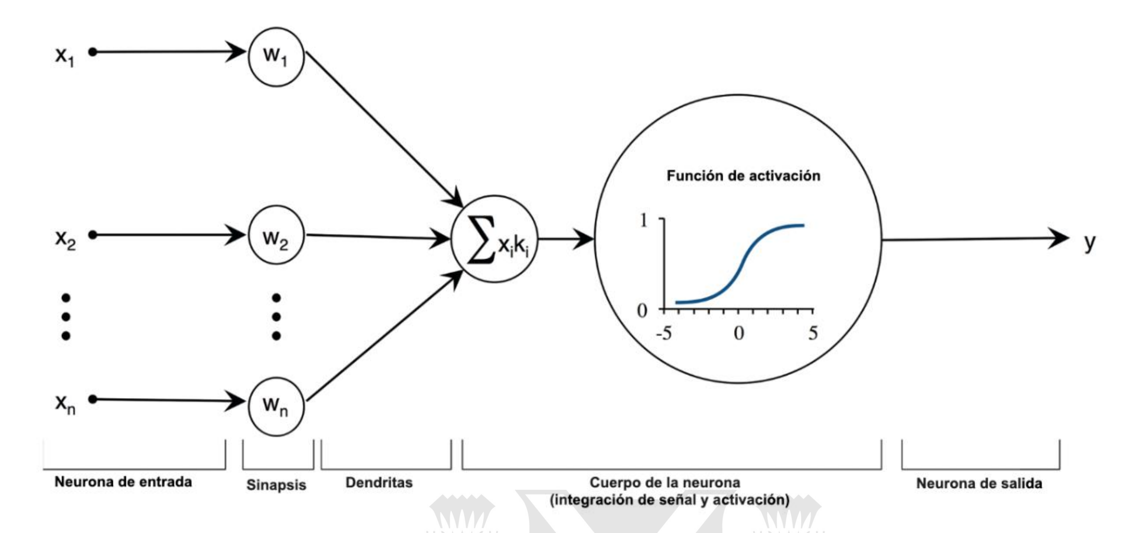
Existen distintos tipos de algoritmos en ML. Redes Neuronales Artificiales, *K-nearest neighbors, Support vector machines,* Árboles de decisión, algoritmos *Naive Bayes*, son algunos ejemplos. En este trabajo nos encargaremos de describir exclusivamente de las Redes Neuronales Artificiales.

2.2.2 Redes Neuronales Artificiales

Las Redes Neuronales Artificiales (en adelante, RN) son modelos de ML que consisten en una multitud de unidades de procesamiento, llamadas neuronas, las cuales son interconectadas unas a otras y son distribuidas en capas, de tal forma que emulan en forma simple la estructura neuronal de un cerebro (Mazurowski, Buda, Saha, & Bashir, 2018).

La unidad de la RN es la neurona, llamada Perceptron. El conjunto de esos Perceptrones hace a una RN (Wikipedia, 2019). El Perceptron toma como entrada un conjunto de valores que representan características, cada una se multiplica por un coeficiente denominado **peso**. Los resultados de ese proceso de multiplicación (de la entrada por el peso) son sumados e ingresados como entrada a una **función de activación**, la cual generará un resultado de salida (Chartrand et al., 2017).

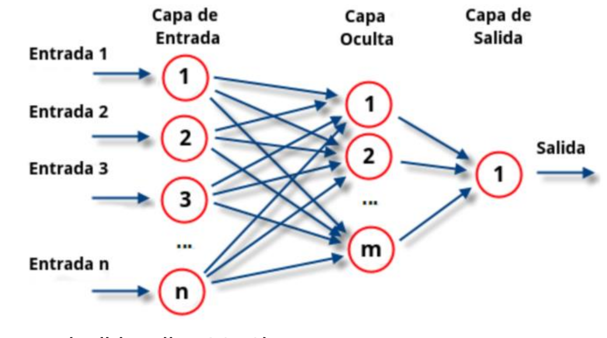
Figura 1. Perceptron.



Ref. Estructura de un Perceptron. - Fuente: Elaboración propia a partir de (Chartrand, 2017).

Las RN llamadas Perceptrones Multicapa son construidas mediante el ensamblaje de neuronas, las cuales forman capas. Las mismas se encuentran conectadas de manera tal que la salida de una capa N se convierte en la entrada de la capa N+1. La primera capa es llamada "capa de entrada", la cual representa los datos de entrada. Mientras que la última capa es llamada "capa de salida" y representa el resultado. Las capas intermedias son llamadas "capas ocultas" dado que no generan salidas visibles (Chartrand et al., 2017).

Figura 2. Estructura de un Perceptrón Multicapa.



Fuente: (Wikipedia, 2019).

La obtención de la predicción de una observación, por ejemplo de una imagen, involucra la activación de cada nodo de cada capa, desde la capa de entrada hasta la capa de salida. Este proceso es llamado "***forward propagation***". Generalmente, el resultado de la capa de salida es procesado por una Función de Costo o Error (comúnmente se utiliza la función softmax), la cual realiza una transformación a un número que representa una probabilidad.

Los ajustes de la red se realizan modificando los valores del peso y características de los distintos nodos. El algoritmo que realiza dicha modificación es llamado **"*gradient descent*"**, el cual intenta encontrar la combinación de parámetros que haga del resultado de la Función de Costo lo más pequeño posible, para el set de datos utilizado. Cada vez que se realiza una predicción a través del proceso de "*forward propagation*" la red es evaluada por su resultado de salida, el cual determina el error en la predicción. Los parámetros son ajustados de manera tal que el error se reduzca. Este proceso es llamado **"*back propagation*"** (Chartrand et al, 2017).

Una de las mayores limitaciones que poseen los Perceptrones Multicapa es su bajo desempeño para procesar imágenes, las cuales requieren una gran complejidad computacional. Es por esto que generalmente para realizar este tipo de procesamientos se recurre a otro tipo de aprendizaje, denominado DL (O'Shea & Nash, 2015). El desafío más grande en la utilización de RN es que las mismas no deben funcionar bien únicamente con las entradas utilizadas en la etapa de entrenamiento sino también con las entradas utilizadas posteriormente. La habilidad para funcionar con datos no conocidos previamente se denomina **generalización**.

Generalmente, a la hora de entrenar un modelo de ML, se tiene acceso a un conjunto de datos de entrenamiento. Los errores de medición con el conjunto de datos de entrenamiento se denominan **error de entrenamiento**. Por otro lado, los errores de medición, dado una nueva entrada en una red puesta a prueba, se denominan **errores de generalización o de prueba** (Goodfellow, 2015).

Los factores que determinan el grado de eficacia de una RN están dados por el concepto de **sub adaptado** (en inglés, *underfitting*) y **sobre adaptado** (en inglés, *overfitting*). El primero sucede cuando el modelo no es capaz de obtener un error suficientemente pequeño, con los datos de entrenamiento. Por otro lado, el segundo sucede cuando la diferencia entre el error de entrenamiento y el de prueba es demasiado grande (Goodfellow, 2015).

Si un modelo se encuentra sobre adaptado se debe considerar reducir su capacidad (por ejemplo, reduciendo el número de parámetros) o agregando más datos de entrenamiento (Chartrand et al., 2017). Esta es la razón principal para reducir la complejidad de las RN, a menor cantidad de parámetros a entrenar, menor la posibilidad de sobreadaptación de la red y mejores resultados de predicción del modelo (O'Shea & Nash, 2015).

2.2.3 Deep Learning

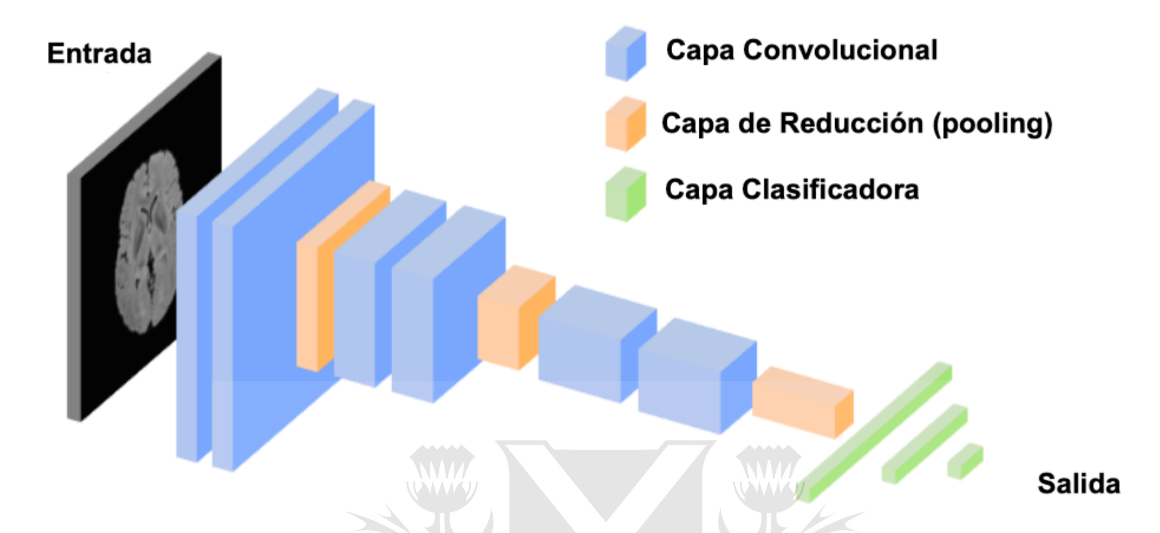
DL es un tipo de aprendizaje en el cual los algoritmos aprenden una composición de características (en inglés, *features*) que reflejan la estructura jerárquica de los datos. Representaciones complejas son expresadas en términos de representaciones simples. Poseen una arquitectura que las hace particularmente buenas para clasificar imágenes (Chartrand et al., 2017).

Aunque no es la única arquitectura, la Red Neuronal Convolucional (en adelante, RNC) es la arquitectura más utilizada dentro de DL. La misma, si bien hereda las propiedades de las RN, posee sus características específicas (Lopez Briega, 2016).

Las RNC poseen una estructura que consta de tres tipos de capas: convolucional, de reducción (también conocida como *pooling*) y clasificadora, las cuales detallamos a continuación.

QUAERERE VERUM
Universidad de
SanAndrés

Figura 3. Representación de una RNC.

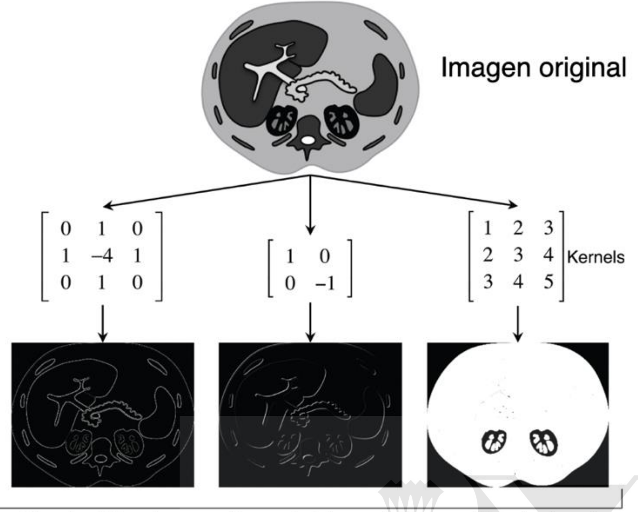


Ref. Representación de de una RNC. En la misma se aplica una serie de capas convolucionales y de *pooling* para luego pasar por la capa clasificadora. - Fuente: Elaboración propia a partir de (Mazurowksi, 2018).

Capa Convolucional

Es la capa que le da nombre a la arquitectura. La operación de convolución recibe, como entrada, la imagen a clasificar. Luego aplica sobre ella un filtro (también conocido como *kernel*), la cual devuelve como salida un *mapa de características* de la imagen original. De esta manera, se logra reducir el tamaño de los parámetros (Lopez Briega, 2016). Es decir, su objetivo es quitarle complejidad a la imagen recibida como entrada.

Figura 4. Aplicación de Kernels sobre una imagen.



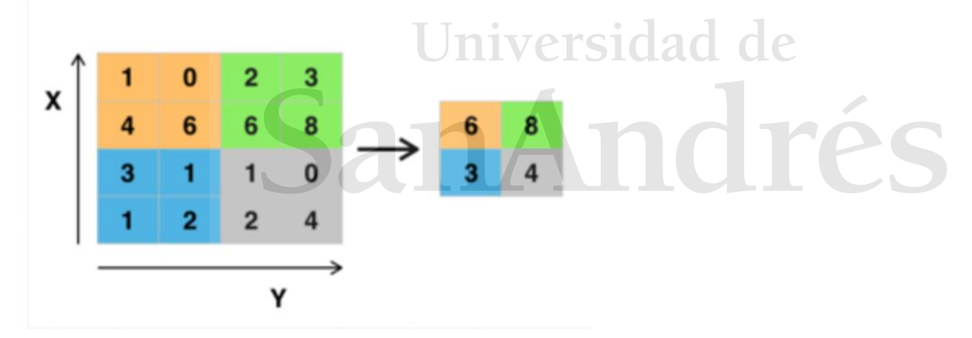
Ref: Ejemplo de aplicación de un *kernel* sobre una imagen. A partir de los mismos se logra extraer distintos características como, por ejemplo, contornos. - Fuente: Elaboración propia a partir de (Chartrand, 2017).

En palabras del Ing. Carlos Selmo "…hablar de convolución o correlación es lo mismo. Y la operación de correlación se puede analizar, matemáticamente, como la búsqueda de cuánto hay de una forma de onda, unidimensional o bidimensional, en una señal más grande. Por lo tanto, la convolución es tomar una pequeña forma de onda (el *kernel*) e ir pasándola por una imagen, secuencialmente. Es decir, ir realizando un barrido, e ir observando cuánto tiene la imagen analizada de la forma del *kernel*, en cada una de sus posiciones. El *kernel* tiene como objetivo la búsqueda de un *feature* en particular, como pueden ser, por ejemplo, bordes, cambio en el brillo de mayor intensidad a menor intensidad, o viceversa. Para lograr esto, el *kernel* se va moviendo sobre la imagen a analizar y va buscando cuánto de sí mismo encuentra en la imagen. Por otro lado, el valor de los *kernel* se va a ajustando, a través del proceso de *backpropagation* de manera tal que haga cada vez más pequeña la función de costo" (C. Selmo, comunicación personal, 17 de junio de 2019).

Capa de Reducción (*pooling*)

Es la capa que se ubica a continuación de la capa convolucional. Su objetivo es la reducción de dimensiones espaciales (ancho y alto) del volumen de entrada, para así brindarlo como entrada en la siguiente capa convolucional. Esta capa también es denominada Reducción de Muestreo, por el hecho de que la reducción de tamaño conlleva una pérdida de información. Si bien, a primera vista, podría ser visto como un problema, en la realidad aporta dos beneficios importantes. El primero es que la reducción de tamaño genera una menor sobrecarga para realizar cálculos en las subsiguientes capas de la red. Por otro lado, también colabora para que no se genere una sobre adaptación de la red. La operación que suele utilizarse para esto es la de *Max-pooling*, la cual divide a la imagen de entrada en un conjunto de rectángulos. Como se puede ver en el ejemplo de la Figura 5, de cada subregión, se queda con el máximo valor (Lopez Briega, 2016).

Figura 5. Aplicación de la función Max-pooling.



Ref. Ejemplo de cómo, de una subregión, la función *max-pooling* obtiene el valor máximo. - Fuente: (Briega, 2016).

Según el Ing. Carlos Selmo "…el motivo por el que se guarda el valor máximo de cada subregión es que el mismo hace referencia a una mayor presencia del *feature* que se estaba buscando con un *kernel* determinado" (C. Selmo, comunicación personal, 17 de junio de 2019).

Capa Clasificadora

Según Carlos Selmo “luego de que se itere una N cantidad de veces sobre la Capa Convolucional y la Capa de Reducción, se utiliza una capa completamente conectada. Generalmente se trata de un Perceptrón Multicapa, en la que cada pixel es considerado como una neurona separada, tal cual las RN convencionales. El objetivo de esta capa es realizar la clasificación de las extracciones que se han realizado en las capas convolucionales y de reducción” (C. Selmo, comunicación personal, 17 de junio de 2019).

2.3 Visión Artificial

La visión de computadora es una rama de las ciencias de la computación que extrae imágenes del mundo físico y las reconstruye, teniendo en cuenta sus propiedades, como forma, iluminación y distribución de colores (Szeliski, 2010).

Es un campo multidisciplinario que puede ser intepretado como un subtitpo de IA y de ML (Brownlee, 2019).

Las tareas de visión más utilizadas son:

- **Clasificación**: es el proceso a través del cual se le asigna una etiqueta a una imagen. Esto es útil cuando hay una sola clase en la imagen y es claramente visible. Un claro ejemplo es la clasificación de gatos y perros.
- **Detección**: la diferencia entre la clasificación y la detección es que, en la detección, puede haber múltiples instancias de la misma clase o de clases diferentes en a misma imagen. Si bien la clasificación solo muestra cuál es la clase probable de la imagen, la detección va un paso más allá y dibuja un cuadro delimitado en la imagen (conocida como *bounding box*). Un ejemplo podría ser el de una imagen con un gato y un perro, cada uno con un *bounding box* alrededor de ellos.

- **Segmentación:** son una extensión de la detección de objetos, en donde se detectan varias clases en una misma imagen, pero en lugar de generar un *bounding box*, la ubicación es definida a nivel de píxel. Es decir, marcando el contorno de la clase es marcado píxel por píxel (Deep Learning Analytics, 2018).

A continuación, realizamos una descripción de la llamada Cuarta Revolución Industrial, para luego comprender el impacto que la misma puede tener en la economía global y el trabajo de las personas.

2.4 Cuarta Revolución Industrial

2.4.1 Caracterización del fenómeno

Para comprender cómo el mundo llega a esta nueva era de grandes desafíos, Klaus Schwab, fundador y líder del World Economic Forum (WEF) en su libro, "*The Fourth Industrial Revolution*", comienza haciendo un breve repaso de cuáles fueron las primeras tres revoluciones industriales que permitieron llegar a esta última.

La Primera Revolución Industrial comenzó en 1760 y duró hasta 1840. La misma fue impulsada por la construcción de vías de tren y la invención del motor a vapor, lo cual marcó el comienzo de la producción mecánica. La Segunda Revolución Industrial, la cual comienza a fines del siglo XIX y duró hasta principios del siglo XX, generó la producción a escala, gracias a la llegada de la electricidad y de la producción en serie. La Tercera Revolución Industrial comenzó a principios de la década del sesenta. La misma es usualmente conocida como la revolución digital ya que fue catalizada por el desarrollo de semiconductores, computadoras *mainframe* (en la década del sesenta), computadoras personales (década del setenta y ochenta) e internet (década del noventa) (Schwab, 2017).

Schwab considera que el comienzo del siglo XXI está dado por el comienzo de la Cuarta Revolución Industrial, la cual se monta sobre los avances de su antecesora.

La misma se caracteriza por una conectividad móvil de internet y ubicua, por sensores más pequeño, poderosos y económicos y por la IA y ML.

La Cuarta Revolución Industrial crea un mundo en el cual los sistemas virtuales y los de manufactura cooperan entre sí de una manera flexible, permitiendo productos mucho más personalizados y la creación de nuevos modelos operacionales. Aunque no se trata únicamente de máquinas y sistemas inteligentes interconectados. También se caracteriza por los nuevos avances de la secuenciación genética, la nanotecnología, energías renovables, computación cuántica. Es la fusión de estas tecnologías y la interacción con el dominio físico, digital y biológico, impactando en todas las disciplinas, economías e industrias (Schwab, 2017).

Si bien no discute los avances que se vienen produciendo en relación a las tecnologías que caracterizan a esta etapa, el Dr. Federico Milano se permite dudar si realmente nos encontramos ante una Revolución Industrial. "…Es complejo poder aseverar ese tipo de cosas en el momento en el que suceden los hechos. En general, tiene que pasar un tiempo para luego mirar hacia atrás y observar realmente el impacto de ciertas tecnologías, más cuando hay tanto *hip*, marketing e intereses en juego. Tal vez estemos transitando la Cuarta Revolución Industrial, o tal vez no, y dentro de unos años veamos que, si bien mejoró mucho la automatización, fue un paso más incremental que algo explosivo" (F. Milano, comunicación personal, 6 de junio de 2019).

En el libro Industria 4.0 (Ana Inés Basco, Gustavo Beliz, Diego Coatz, 2018), los pilares de la Cuarta Revolución Industrial están caracterizados por las siguientes tecnologías:

- Sistemas Integrados: integración de tecnologías operacionales con tecnologías de información y la comunicación. Conecta máquinas con

máquinas, máquinas con productos. Permite integrar empresas con otros actores de la cadena de valor (por ejemplo, logística, cliente).

- Máquinas y sistemas autónomos (robots): máquinas a través de las cuales se automatiza parte de la matriz de producción, la cual era previamente exclusiva de dominio humano.
- Internet de las cosas (IoT): dotando de conectividad a máquinas que previamente no la tenían, generando una comunicación entre éstas, las personas y los productos. Facilita la toma de decisiones de la tecnología en base a la información que va recogiendo del entorno.
- Manufactura aditiva (impresión 3D). Permite la fabricación de objetos tomando únicamente como referencia modelos virtuales, dejando los viejos moldes de lado.
- Big Data. Análisis de grandes volúmenes de datos, estructurados y no estructurados. Una de las tecnologías más demandadas a nivel empresarial.
- Computación en la nube: proporciona almacenamiento, acceso y uso de servicios en línea de infraestructura, plataformas y software.
- Simulación de entornos visuales. Ambientes virtuales de prueba y simulación que permiten ajustar y representar el funcionamiento de un conjunto de máquinas, procesos y personas en tiempo real.
- IA. Desarrollo de algoritmos que permiten procesar datos a una velocidad inusual, logrando además aprendizaje automático.
- Ciberseguridad: herramienta utilizada para que el resto de las tecnologías mencionadas funcionen correctamente. Permiten detectar, anticipar y neutralizar amenazas sobre los sistemas.
- Realidad aumentada: complementa el entorno real con objetos digitales.

Schwab también tiene preocupaciones acerca de esta nueva etapa. Las mismas están basadas en que las organizaciones deben ser lo suficientemente flexibles como para adaptarse, los gobiernos podrían fallar en el uso y la regulación de nuevas tecnologías, el cambio de poder crearía nuevos preocupaciones importantes

en materia de seguridad, la inequidad podría llegar a crecer y la sociedades podría fragmentarse (Schwab, Chairman, & Forum, 2016).

Solo se verán beneficiados de esta nueva etapa quienes sean capaces de innovar y adaptarse. Desde el inicio del siglo XXI, poco más del 50% de las empresas que formaron parte del Fortune 500[16] han desaparecido. En la misma línea, las consecuencias de la Cuarta Revolución Industrial puede ser aún mayores (Nanterme, 2016).

Según la consultora Accenture, la llamada Cuarta Revolución Industrial aportará a la economía mundial $14,2 trillones de dólares durante los próximos quince años (Perasso, 2016).

Figura 6. Rotación de empresas pertenecientes al ranking Fortune 500.



Ref: Impacto de la Cuarta Revoución Inudustrial en las empresas que componen el listado de Fortune 500. Se estima que entre el 2018 y el 2023 la rotación de las mismas puede ir entre un 47% (si la tasa de rotación es lineal, a un 81% (si la tasa de rotación es exponencial). - Fuente: Elaboración propia a partir de *When the human body is the biggest data platform, who will capture value?* (Licking, Evans, & Bean, 2018).

16. Fortune 500 es un ranking anual, publicado por la revista Fortune, de las 500 empresas más grandes del mundo, de acuerdo a su facturación.

2.4.2 El impacto de la IA en el trabajo

Con el desarrollo de la IA, algunas de las preguntas más escuchadas están relacionadas al futuro del trabajo y a el lugar del ser humano en el proceso de producción.

A través de una investigación realizada sobre 700 trabajos actuales se arribó al veredicto de que 47% de ellos se encuentran en alto riesgo de ser automatizados en los próximos 10 o 20 años (Frey & Osborne, 2013).

Según la consultora PWC en su informe "*Sizing the prize*", publicado en 2017, la adopción de tecnologías que no requieran de la decisión humana conlleva que muchos puestos de trabajo sean innecesarios. Pero a su vez, otros nuevos se crearán a causa de los cambios en productividad y de nueva demanda de los consumidores. Por otro lado, una parte de los nuevos trabajadores tendrán que poner foco en idear nuevas formas de IA y su desarrollo, otro conjunto de nuevos trabajadores serán requeridos para construir, mantener, operar y regular esas nuevas tecnologías emergentes. Un ejemplo es que se podrá necesitar el equivalente a controladores del espacio aéreo para dar control a los autos autónomos en el tránsito.

En el libro Surviving IA, Chace (2015) desarrolla esta temática. La automatización fue siempre una característica de la civilización humana. En el siglo XV, transcurriendo la Primera Revolución Industrial, el desarrollo de motores traccionados a vapor y luego el carbón, llevaron a la automatización a un nuevo nivel. Un ejemplo clásico es la mecanización de la agricultura, la que representaba el 41% del empleo en 1900 y solo un 2% en 2000.

A fines del siglo XX, el proceso de automatización se centró en los robots, particularmente en la industria automotriz y eléctrica, y esto se acelerará. Los robots son periféricos de la IA. A pesar de la recesión, las ventas de robots crecieron un 10% anual entre 2008 y 2013, vendiéndose 178.000 robots industriales en todo el

mundo. China, por otra parte, se convirtió en el mercado más grande, instalando 37.000 robots, en comparación con 30.000 en los Estados Unidos.

El proceso de automatización también ha dejado obsoletos grandes cantidades de puestos de oficina. En el pasado la palabra “computadora” hacía referencia a las personas que hacían cálculo. Las computadoras han reemplazado este puesto como así también a muchísimas secretarias.

El miedo de la pérdida del trabajo a causa del progreso en la tecnología no es nuevo. Solo es cuestión de analizar los titulares de la revista *The New York Times* del último siglo: “*La Marcha de las Máquinas hace las Manos Ociosas*” (26 de febrero de 1928); “*¿Desplaza la máquina al hombre a largo plazo?*” (25 de febrero de 1940); “*200.000 personas perderán el empleo frente a la automatización*” (5 de mayo de 1962); “*Un robot está tras tu trabajo*” (3 de septiembre de 1980); *“¿Tomarán los robots el trabajo de nuestros hijos?*” (11 de Diciembre de 2017) (Langlotz, 2019).

El economista británico Keynes (1930) hace referencia al desempleo tecnológico como una nueva enfermedad de la cual se escucharía por sucesivos años. El mismo surge debido al descubrimiento de medios para economizar el uso de la mano de obra que supera el ritmo al que se le puede encontrar nuevos usos para la mano de obra. Pero, por otro lado, esto será únicamente una fase temporal de ajuste.

Se estima que el 47% de los empleos en Estados Unidos desaparecerían en los próximos 20 años. Esto se produciría en dos etapas. La primera atacaría empleos relativamente poco calificados en transporte y administración. La segunda ola de automatización pronosticada afectará los empleos en el corazón de la clase media y media alta: ocupaciones profesionales como la medicina y la ley, empleos gerenciales e incluso en las artes. La afirmación es que los sistemas como Watson de IBM pasarán de ser sistemas de soporte de decisiones a sistemas de toma de decisiones. A medida que aumente la capacidad de las máquinas para convertir los datos en bruto en información y luego mejorar la percepción, el espacio restante

para que un humano agregue valor se reduce y, finalmente, desaparece (Frey & Osborne, 2013).

El Dr. Daniel Luna agrega “La paradoja es que antes se automatizaba lo manual. En la Cuarta Revolución Industrial se comienza a automatizar toda tarea cognitiva. Ahora, lo que le podrá dar la diferencia a los trabajadores, es el trabajo caracterizado por su componente manual. En el caso de la medicina, las especialidades manuales son las que más posibilidades tienen de persistir, como las conocemos hoy. Pero todas, en mayor o menor medida, serán alcanzadas por algún tipo de IA” (D. Luna comunicación personal, 24 de mayo de 2019).

Por último, el Dr. Facundo Manes, no considera que el trabajo del hombre corra un peligro real. “La Cuarta Revolución Industrial, a diferencia de las previas, nos está cambiando a nosotros. Porque hay una fusión de lo biológico, lo digital y lo físico. La IA no nació ahora, tiene décadas de existencia. Y siempre hubo predicciones aterradoras de que el robot va a reemplazar al ser humano, desde hace décadas. Y nunca sucedió. En la última etapa, la IA ha avanzado y esto requiere una ética de cómo se controlará. No creo que esto sea una amenaza para el trabajo tan grande como se plantea. En las diferentes revoluciones industriales la tecnología amenazó al trabajo y la gente tuvo miedo. Pero siempre el ser humano terminó complementándose con la tecnología moderna. Lo que se requiere es que nos eduquemos mejor, que todos volvamos a aprender. Más que una amenaza o parálisis por la IA y el resto de las tecnologías, veo una posibilidad de que los humanos y esas tecnologías coexistan en colaboración. Ese es el desafío. Y para eso necesitamos educarnos y reinventarnos” (F. Manes, comunicación personal, 29 de mayo de 2019).

2.4.3 El impacto de la IA en la economía

Hay dos factores clave en el actual auge y crecimiento de la IA. El primero consta de la capacidad de almacenamiento y procesamiento de datos que hoy está

ofreciendo los servicios de computación en la nube, donde los costos asociados del servicio son variables y decrecientes en el tiempo. En este sentido, la consultora Accenture estimó que el mercado de la computación en la nube pública alcanzó, globalmente, en 2015, una cifra cercana a los $70.000 millones de dólares. El otro factor clave es el Big Data[17]. Esta herramienta nos permite acceder a una enorme cantidad de datos de forma sencilla y ordenada (Ovanesso & Plastino, 2017). La IA puede contribuir a la economía mundial, para 2030, con $15,7 trillones de dólares. Un número que supera el aporte a la economía actual de China e India. Dicho número puede descomponerse en $6,6 trillones provenientes de un crecimento en la productividad y $9,1 trillones provenientes del consumo. Dentro de dicho aporte, China y Norte América serían los máximos beneficiados, haciéndose de un casi 70% del crecimiento (PWC, 2018).

Figura 7. Contribución estimada de IA a la macroeconomía mundial en 2030.

Región	Impacto económico de la IA	% del Total
China	$7.0 trillion	44.6%
América del Norte	$3.7 trillion	23.6%
Europa del Norte	$1.8 trillion	11.5%
Asia desarrollada	$0.9 trillion	5.7%
Europa del Sur	$0.7 trillion	4.5%
América Latina	$0.5 trillion	3.2%
Resto del mundo	$1.2 trillion	7.6%
Total	**$15.7 trillion**	**100.0%**

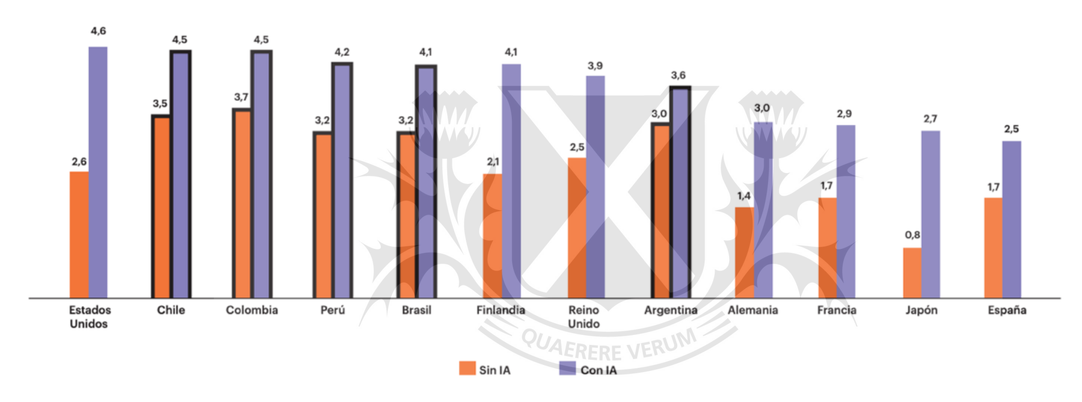
Ref: Contribución estimada de la IA a la macroeconomía mundial para 2030.
Fuente: Elaboración propia a partir de *The macroeconomic impact of the artificial intelligence* (PWC, 2018).

[17] El concepto de Big Data refiere a grandes cantidades de datos complejos, tanto estructurados como no estructurados, los cuales no pueden ser procesados a través de las técnicas tradicionales de procesamiento de datos. Su objetivo es revelar patrones ocultos y ha llevado a una evolución del paradigma de *model-driven* al de *data-driven* (Kevin Taylor-Sakyi , 2016).

Son dos los factores clave que permiten el crecimiento de de la IA:

- Acceso ilimitado al procesamiento de las computadoras, en donde el mercado de la nube llega casi a $70 billones de dólares en 2015 en todo el mundo.
- Crecimiento en Big Data, en donde la tasa de crecimiento anual compuesto[18] supera al 50% desde el 2010 (Ovanesso & Plastino, 2017).

Figura 8. Impacto estimado de la IA en las tasas de crecimiento económico.



Ref: La IA posee el potencial de aumentar las tasas de crecimiento económico hasta en 1 punto porcentual en términos del valor agregado bruto. - Fuente: *Cómo la Inteligenia Artificial puede generar crecimiento en Sudamérica* (Ovanesso & Plastino, 2017).

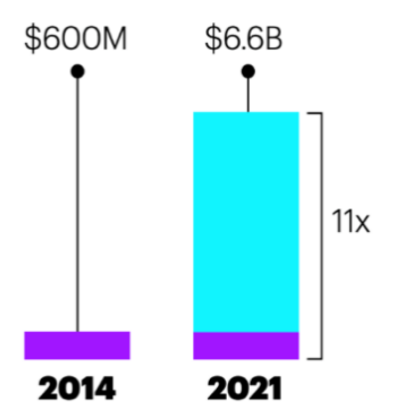
Universidad de SanAndrés

2.5 IA en los sistemas de salud

Hay una expectativa de que las inversiones públicas y privadas de IA en salud alcancen para 2021, solo en Estados Unidos, los $6,6 billones de dólares. Un gran crecimiento si se toma en cuenta que en 2014 las inversiones fueron de $600 millones de dólares (Collier et al., 2017).

18. Para más información: https://en.wikipedia.org/wiki/Compound_annual_growth_rate#Applications

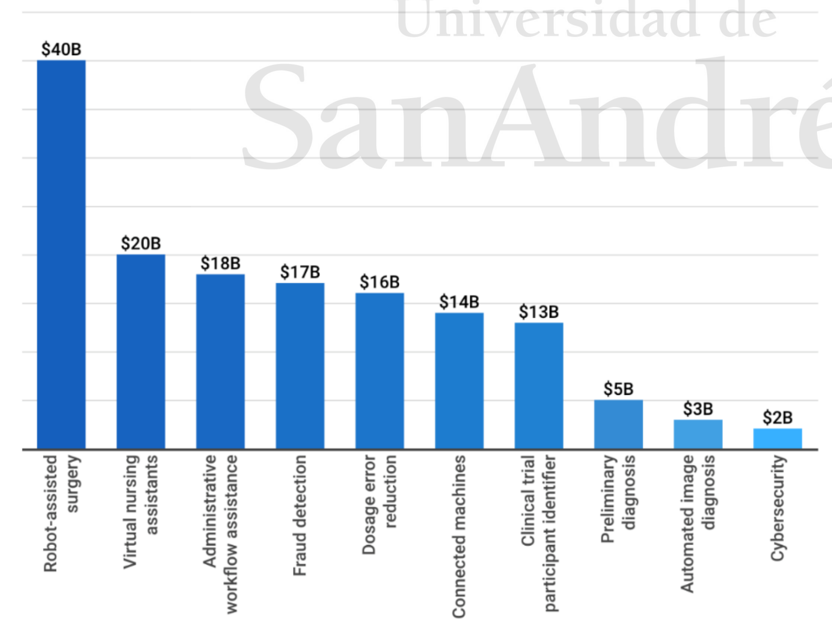
Figura 9. Crecimiento de las inversiónes en IA



Ref: Crecimiento de las inversiones de IA en salud desde 2014 al 2021. - Fuente: *AI: Healthcare´s New Nervous System* (Collier et al., 2017).

Por otro lado, tomando los principales usos que se le dará a la IA en salud, el mismo informe estima que se generará, en 2026 en Estados Unidos, beneficios por $150 billones de dólares. De dichas cantidades, se estima un valor anual para el DPI de $3 billones de dólares (Collier et al., 2017).

Figura 10. Beneficio de IA en las verticales de salud en 2026.



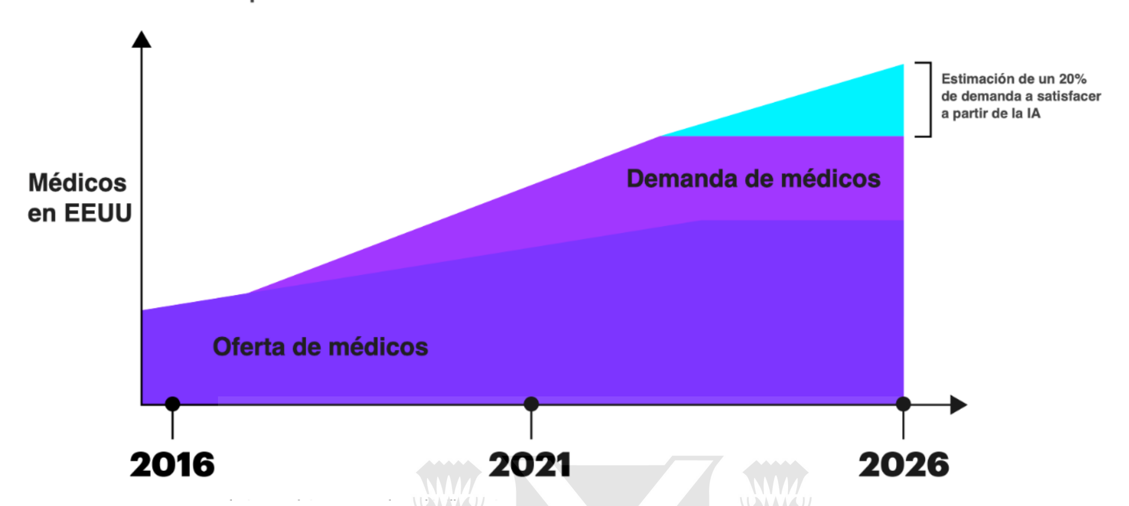
Ref: Estimación del beneficio que generarán, para 2026, las distintas verticales de IA en salud - Fuente: "*AI: Healthcare´s New Nervous System*" (Collier et al., 2017).

Para el Dr. Diego Slezak el impacto de IA/ML en el mercado de la salud se puede caracterizar en términos cualitativos y cuantitativos. “Desde lo cualitativo, va a cambiar la forma en que accedemos al sistema de salud. Hay muchos estudios que demuestran que pagamos mucho dinero en un servicio que tarda en llegar y es de mala calidad. La IA y ML tiene el potencial de cambiar esto, a través de una medicina más personalizada, más barata y que sea de más fácil acceso, tanto en tiempo como en oportunidades. Desde lo cuantitativo, la cantidad de dinero que se gasta mal en salud es monstruosa. Ahí tiene mucho para aportar IA y ML. El sistema será más eficiente, probablemente se gasten las mismas sumas de dinero, pero de mejor forma” (D. Slesak, comunicación personal, 28 de mayo de 2019).

2.5.1 Impacto de la IA en la democratización de la salud

“La democratización implica aplicar las normas y los procedimientos de la ciudadanía a instituciones que estaban regidas por otros principios, como el control coactivo, la tradición social, el juicio de los especialistas o las prácticas administrativas. La democratización también supone aplicar estas normas y procedimientos a individuos que antes no gozaban de tales derechos y obligaciones, como las mujeres, los jóvenes o las minorías étnicas” (Frenk & Gómez-Dantés, 2001). A partir de tal definición, el informe de Microsoft “Democratizar la IA” de 2016, plantea sacar la IA de la torre de marfil en donde se encontraba y hacerla más accesible para todo el mundo. Como consecuencia de la democratización de la IA, la demanda de servicios de salud crecerá enormemente. Para 2026, se estima un aumento de la demanda de hasta un 20% (Collier et al., 2017).

Figura 11. Crecimiento de la demanda en función de la implementación de IA.



Ref: Estimación del crecimiento de la demanda que generará la democratización de la IA en Estados Unidos para 2026. - Fuente: Elaboración propia a partir de *Artificial Ingelligence: Healthcare´s New Nervous System* (Collier et al., 2017).

2.5.2 Etapas en las que IA aporta valor en la salud

PWC en su informe "*What doctor?"* publicado en 2017, detalla las distintas etapas, vinculadas al paciente, donde la IA puede intervenir y generar valor. Las etapas son prevención, detección temprana, diagnóstico, tomas de decisiones, tratamiento, geriatría, investigación y capacitación.

- **Prevención**. Se trata de ayudar a las personas a mantenerse sanas de manera tal que no necesiten un doctor, o que lo necesiten lo menos posible. La utilización de IA y de la *Internet of Medical Things* (IoMT) con aplicaciones de salud ya está ayudando a las personas a administrar su salud y mantenerse saludables. Por otra parte, también aumenta el entendimiento que tienen los profesionales acerca de patrones que se puedan desprender del día a día. Un ejemplo es Fitbit[19].

19. Fitbit es una marca de wearables los cuales permiten, entre otras funciones, realizar un control de la actividad física realizada por el usuario y de sus horas de sueño. Para más información: https://www.fitbit.com/ar/home

- **Detección Temprana**. La IA es utilizada para detectar enfermedades en su etapa inicial. Como ejemplo tenemos al Apple Watch[20] y su capacidad de realizar electrocardiogramas.

Solo en estas dos primeras etapas, Goldman Sachs estima podrá ahorrar, anualmente, al sistema de salud de Estados Unidos, $200 billones de dólares. A partir de estos números, la consultora BCG estima que, para 2022, la industria de salud invierta en estas dos etapas, anualmente, $2,1 billones de dólares (Aboshiha et al, 2019).

- **Diagnóstico**. La posibilidad que brinda la IA al analizar información no estructurada, nunca antes explotada, habilita un 80% de información extra de salud para abordar (Y. Wang, Kung, & Byrd, 2018). A modo de ejemplo nos encontramos a Watson for Health[21].
- **Toma de decisiones**. El análisis de datos y la toma de decisiones realizada en tiempo y forma son dos de los factores necesarios para mejorar la atención de los pacientes. El análisis predictivo es capaz de dar soporte a la toma de decisiones y a las acciones clínicas como así también priorizar tareas. Citamos como ejemplo a Quanum[22] (Quest Diagnostic).

El diagnóstico temprano y la toma de decisiones pueden recortar los costos a más del 50%. Aproximadamente el 20% de los costos asociados al diagnóstico son salarios, por lo que podría haber un gran ahorro si la IA mejora la eficiencia de los médicos y otros profesionales de la salud. Para 2022, solo en Estados Unidos, los

20. La última versión (Serie 4) del reloj de Apple posee la capacidad de realizar electrocardiogramas de manera tal que, ante determinadas anomalías, puede dar aviso, tanto al usuario como a su médico (Apple Newsroom, 2019).

21. Este producto de IBM, utiliza tanto la información estructurada como la no estructurada para encontrar patrones y elaborar conocimiento que ayuda al diagnóstico y a la toma de decisiones. Para más información: https://www.ibm.com/watson/health/

22. Esta plataforma es una *suite* de herramientas, la cual a través de análisis predictivo, sobre información de estudios médicos del paciente y de su historia clínica, ayuda a los médicos a identificar aquellos pacientes cursando una primera etapa de pérdida de memoria y demencia. Para más infomración: https://www.questdiagnostics.com/home/physicians/healthcareit/quanumsolutions.html

distintos actores del sistema de salud invertirán en estas dos etapas, anualmente, $1,2 billones de dólares (Aboshiha et al, 2019).

- **Tratamiento**. La IA puede ayudar a los médicos a tener mejores aproximaciones de cómo manejar determinadas enfermedades, coordinar de manera más eficiente los planes de atención y ayudar a los pacientes a gestionar y cumplir mejor sus programas de tratamiento a largo plazo. En esta etapa podemos encontrar a Watson for Oncology[23].

En Estados Unidos, los costos directos de los errores médicos en los tratamientos son aproximadamente del 2% de la inversión anual en salud. Esos errores tienen un impacto en la economía global del país en aproximadamente $1 trillón de dólares. En 2022, se invertirán $2,8 billones de dólares en IA para mejorar los tratamientos (Aboshiha et al, 2019).

- **Geriatría**. Dado que la expectativa de vida crece, las enfermedades asociadas a esta etapa también. Demencia, fallas cardíacas, osteoporosis, son algunos ejemplos. Por otro lado, la tercera edad suele estar caracterizada por la soledad de los que la transitan. Es por este motivo que la IA y los robots tienen un gran potencial en la geriatría, ayudando a los ancianos a ser independientes por más tiempo, reduciendo los gastos de interacciones, cambiando la toma de signos vitales y entrega de medicación en geriátricos.

- **Investigación**. El camino de una droga, desde su etapa de investigación hasta su aprobación y consumo, por parte del paciente, es largo y costoso. Aplicando IA, en este proceso, se ayuda a reducir el costo de la investigación y el lanzamiento al mercado. Por lo tanto, también podría bajar el costo del

23. *Watson for Oncology* brinda recomendaciones de tratamiento basado en la historia clínica digital del paciente. Para más información: https://www.ibm.com/us-en/marketplace/clinical-decision-support-oncology

producto, generando un beneficio no solo a los laboratorios, sino también a los pacientes de los cuales su vida depende de estos avances.

El proceso de investigación de una droga tarda en promedio doce años, tiene un costo promedio de $359 millones de dólares y solo 1% de las drogas que se estudian terminan siendo aprobadas para su uso en humanos (California Biomedical Research Association, 2013). El gasto total que se estima en descubrimiento de drogas, para 2022, es de $1,3 billones de dólares (Aboshiha et al, 2019).

- **Capacitación**. La utilización de lenguaje natural y la posibilidad de la IA de ajustar los escenarios, en forma dinámica, hace que la misma pueda responder preguntas, tomar decisiones o consejos para un aprendiz. Los programas de entrenamiento se pueden ajustar en base a las necesidades específicas de cada alumno.

A continuación, explicaremos cómo la IA no solo creará valor al sistema de salud, sino que también tiene la capacidad de transferir el mismo entre los distintos actores de ese sistema.

2.5.3 Transferencia de valor entre actores del sistema de salud

La implementación de IA en el sector de la salud provocará una transferencia de valor, reflejada en: ingresos y ganancias, al exponer ineficiencias, mejorar la toma de decisiones y la calidad de atención. El valor no solo se transferirá entre los actores de la industria (Laboratorios, Prestadores, Seguros, Fabricantes de Soluciones Médicas) sino que también a otros actores, como ser empresas de tecnología y los propios pacientes (Aboshiha et al., 2019).

De acuerdo a Aboshiha et al. (2019) existen tres formas en las que se genera transferencia de valor:

- **Cambios generados por aplicaciones que reducirán los costos dentro de un sector y generarán mayor valor dentro de ese mismo sector**. Un ejemplo para la figura del Prestador son los algoritmos utilizados para llegar a un diagnóstico y la selección del tratamiento adecuado. Ambos mejorarán los resultados y reducirán desperdicios. Los Prestadores conservarán parte de esa eficiencia adquirida a través de una menor cantidad de reingresos (los cuales generalmente generan penalidades por parte de los Seguros) y menores costos hospitalarios.
- **Cambios generados por aplicaciones dentro de un sector que amenazan los ingresos o ganancias de otro sector**. Un ejemplo, para el Prestador, es el uso más eficiente de una droga. Esto generará una transferencia de valor desde los Laboratorios hacia los Prestadores. Pero, por otro lado, las mejoras en el monitoreo y la prevención de enfermedades crónicas reducirán la demanda de servicios de los Prestadores, generando en este caso, transferencia de valor desde el Prestador hacia los Seguros.
- **Aplicaciones dentro de uno de los cuatro actores de la salud que generen una pérdida de valor, transformándose en ganancia para las compañías tecnológicas o hacia los pacientes.** Un ejemplo, también para el Prestador, se da con la mejora en los monitoreos. De esa forma el valor generado se transferirá a las Compañías Tecnológicas y los Fabricantes de Soluciones Médicas, encargados de crear las soluciones basadas en IA.

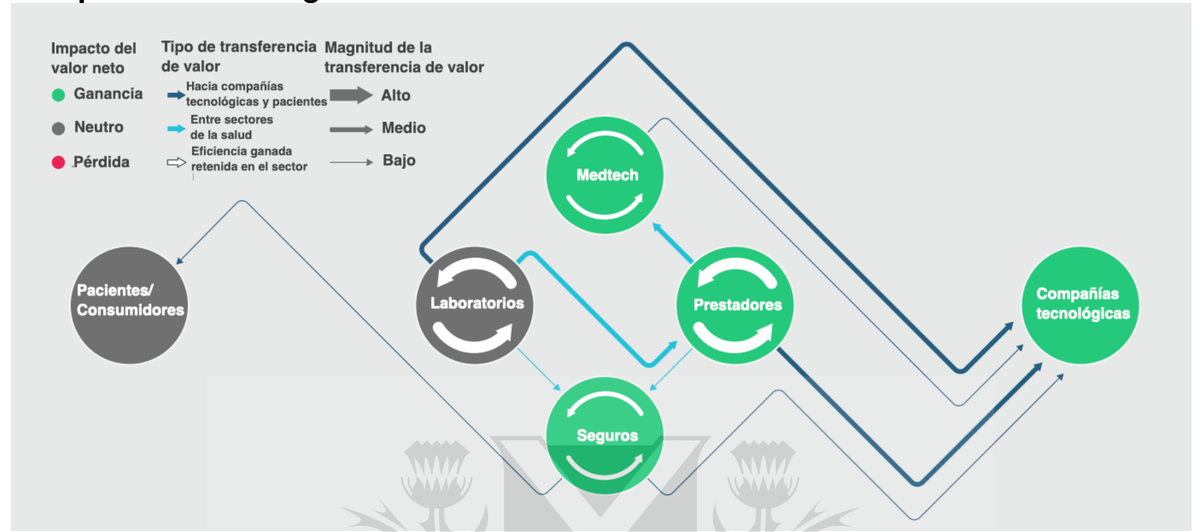
Si todos los actores del sistema de salud implementaran IA en sus procesos, la transferencia de valor podría quedar configurada de múltiples formas. En las figuras 12 y 13 se pueden observar dos ejemplos de transferencia de valor. En el primero, la mayor parte del valor generado por la IA permanece en los actores de la industria y las compañías tecnológicas. En el segundo, la mayor parte del valor generado por IA se transfiere al paciente/consumidor.

Ejemplo 1: Impacto de IA en la transferencia de valor en donde, la mayor parte del mismo, queda concentrado en los actores de la industria y las compañías tecnológicas

- En Pacientes/Consumidores: impacto neutral, el valor de la IA es compartido entre los cuatro sectores de salud (mencionados a continuación) y las compañías tecnológicas.
- En Prestadores: impacto positivo a raíz de una mejora en la eficiencia en las operaciones y la toma de decisiones clínicas.
- En Seguros: impacto positivo dada una mejora en los procesamientos de reclamos y fraude, desechos y detección de abusos.
- En Fabricantes de Soluciones Médicas (Medtech): impacto positivo, dada la mejora en la eficiencia de las operaciones y el aumento de la demanda de dispositivos basados en IA.
- En Laboratorios: impacto neutral, dado que el resultado generado por prevención de enfermedades y el uso más eficiente de drogas se contrarresta con la eficiencia en los procesos de Investigación y Desarrollo.
- En Compañías tecnológicas: impacto positivo, dado el incremento en la demanda de soluciones basadas en IA.

QUAERERE VERUM
Universidad de
SanAndrés

Figura 12. Impacto de IA en la transferencia de valor. La mayor parte del valor generado por IA permanece en los actores de la industria y las compañías tecnológicas.



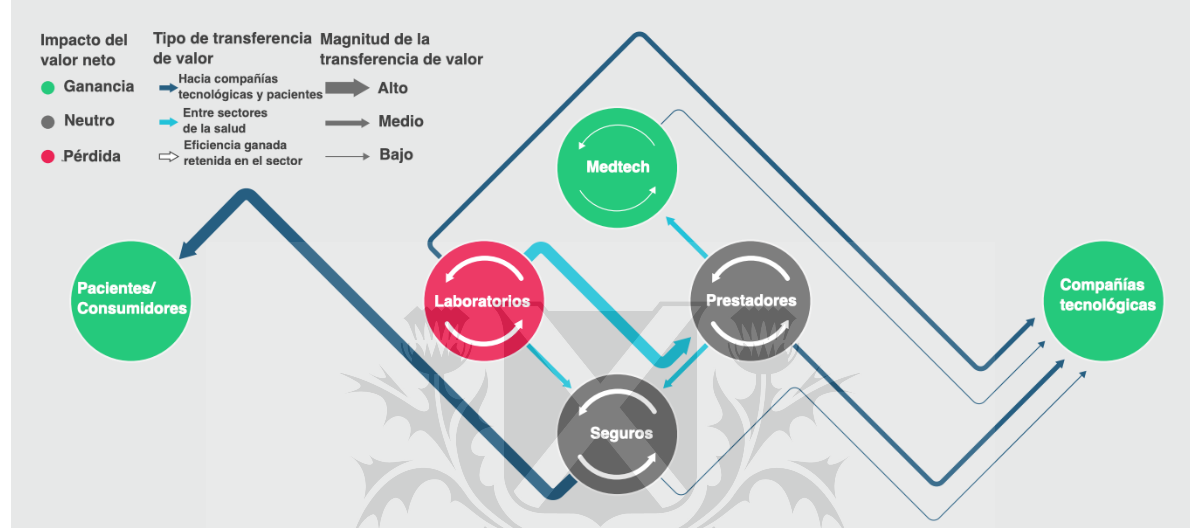
Ref: Ejemplo de impacto de IA en la transferencia de valor en donde, la mayor parte del mismo, queda concentrado en los actores de la industria y las compañías tecnológicas. El ancho de las flechas hace referencia a la magnitud de la transferencia. - Fuente: Elaboración propia a partir de (Aboshiha et al., 2019).

Ejemplo 2: Impacto de IA en la transferencia de valor en donde, parte del mismo, se transfiere al paciente/consumidor

- En Pacientes/Consumidores: impacto positivo, dada la baja en los costos del seguro médico.
- En Prestadores: impacto neutral ya que los Seguros recuperan los ahorros generados por la IA en la operación y la toma de decisiones médicas.
- En Seguros: impacto neutral, dado que el mercado y las presiones políticas harán que tengan que bajar la cuota que se le cobra a sus afiliados.
- En Fabricantes de Soluciones Médicas (Medtech): impacto positivo, dada la eficiencia en las operaciones y el aumento de la demanda de dispositivos basados en IA.
- En Laboratorios: impacto negativo, dado que el mayor foco se encuentra en la prevención de enfermedades y la eficiencia en la prescripción de drogas superan los ahorros generados en Investigación y Dearrollo.

- En Compañías tecnológicas: impacto positivo dada la alta demanda de soluciones basadas en IA.

Figura 13. Impacto de IA en la transferencia de valor. La mayor parte del valor generado por IA se transfiere al paciente/consumidor.



Ref: Ejemplo de impacto de IA en la transferencia de valor en donde, parte del mismo, se transfiere al paciente/consumidor. El ancho de las flechas hace referencia a la magnitud de la transferencia - Fuente: Elaboración propia a paritr de (Aboshiha et al., 2019).

A continuación, haremos un análisis del enfoque que las grandes empresas tecnológicas, como Google, Apple, Microsoft, Facebook, Amazon e IBM le están dando a IA en general y a la IA en salud en particular.

2.6 ¿Qué están haciendo las grandes empresas?

Para caracterizar la revolución que IA significa, el fondo de inversión Woodside Capital Partners detalla, en su informe “*The Top Acquirers in Artificial Intelligence*” publicado en el 2019, una serie de conceptos que ayudan a comprender el fenómeno.

- La revolución en IA está sucediendo en todas las industrias.
- Si bien IA se encuentra en la agenda de todas las empresas tecnológicas, varía mucho lo que está haciendo cada una de ellas. Algunas de las

compañías con política más agresiva respecto a la IA son Alphabet/Google, Amazon y Facebook. Respecto a China: Baidu, Alibaba y Tencent. Por otro lado, compañías de base no tecnológica también reconocen la importancia de adoptar la IA en sus negocios, razón por la cual se encuentran trabajando estratégicamente con compañías como Amazon, IBM, HP, Oracle y Microsoft.

- Compañías como Google Alphabet, Facebook, Microsoft y Amazon, poseen una gran ventaja. Y es que la IA se ve beneficiada de sus grandes infraestructuras, grandes capitales de inversión, grandes redes de Internet de las Cosas, celulares, autos, o redes de consumidores. Todo esto genera inmensos volúmenes de datos. Y a más datos, mayor aprendizaje y predicción que las máquinas podrán realizar.
- China se encuentra a la par de las compañías occidentales en inversión en IA, teniendo planes de inversión, para 2030, de $1 trillón de dólares. Dado que, en IA, el volumen de datos hace a la fuerza, China, con una población de 1,4 billones de personas, es una clara potencia en la materia.

A continuación, describiremos el enfoque y las estrategias que están llevando a cabo Google, Apple, Microsoft, Amazon, Facebook e IBM para abordar a la IA.

2.6.1 Google/Alphabet

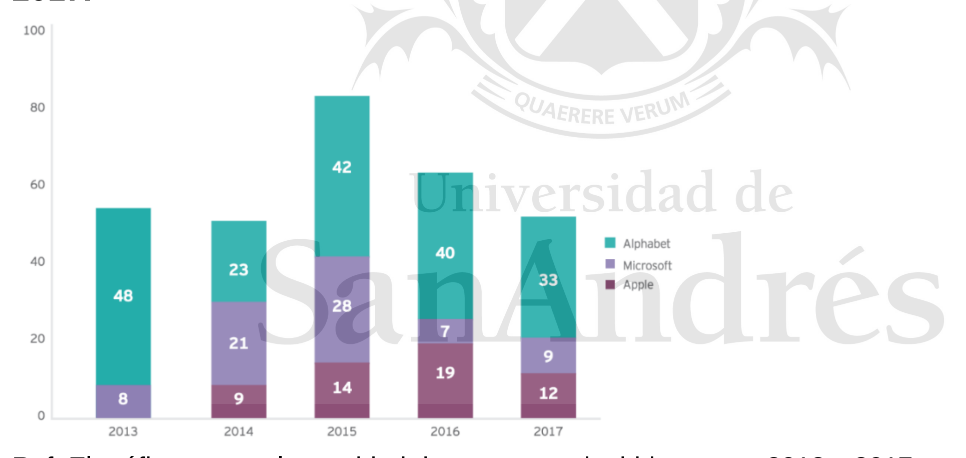
A 2018, Google posee miles de proyectos basados en IA, en desarrollo. Esto se suma a que también es la compañía perteneciente a las “4 Grandes” (Google, Facebook, Amazon y Microsoft) más activa en lo que respecta a adquisiciones e inversiones de aplicaciones y talentos vinculados a la IA, siendo la compañía qué más inversión está realizando (Huynh, 2019).

Desde el 2015, año en que Sundar Pichai asume como CEO de la compañía, la misma ha pasado de ser “*mobile first*” a “*AI-first*”, invirtiendo anualmente más de $10 billones de dólares en infraestructura para la creación de negocios basados en

IA (Porter, 2019). Desde el 2009, año en el que Google, a través de Alphabet, crea Google Ventures (en adelante, GV). Se estima que un tercio del presupuesto que posee GV se destina a *startups* de las verticales de salud y ciencia (Shead, 2017).

GV ya ha invertido en más de sesenta compañías relacionadas con la salud. Solo en 2017, cinco de esas compañías ya son públicas (Spero Therapeutics, Arsanis, Arcus Bioscience, Armo Biosciences y Denali Therapeutics) (The Medical Futurist, 2018). El valor de mercado del *equity* que posee GV sobre esas cuatro compañías es de aproximadamente $153 millones de dólares (D'Onfro, 2018). Entre 2013 y 2017, GV ha alcanzado las 186 patentes relacionadas con el campo de la salud (Licking et al., 2018).

Figura 14. Patentes adquiridas por Alphabet, Microsoft y Apple entre 2013 y 2017.



Ref. El gráfico muetra la cantidad de patentes adquiridas, entre 2013 y 2017, por Google/Alphabet (186 patentes), Microsoft (73 patentes) y Apple (54 patentes) - Fuente: *When the human body is the biggest data platform, who will capture value?* (Licking et al., 2018).

Google, a diferencia de sus rivales, concentra el porcentaje más alto de tráfico de información en internet. Aprovechando toda la información que tiene a disposición, y haciendo uso de IA y ML, se puede posicionar como el líder en empresas de salud innovadoras (Porter, 2019). Google destina gran parte de los proyectos de salud en alguna de sus tres adquisiciones: Verily Life Sciences, DeepMind y Calico. Las

mismas, junto a la división Google Brain[24], han generado asociaciones con investigadores y bioinformáticos de la Universidad de San Francisco, la Facultad de Medicina de la Universidad de Stanford y la Facultad de Medicina de la Universidad de Chicago. El objetivo de estas asociaciones es explorar como ML, en combinación con la experiencia médica, puede mejorar la atención a los pacientes (Chou, 2017).

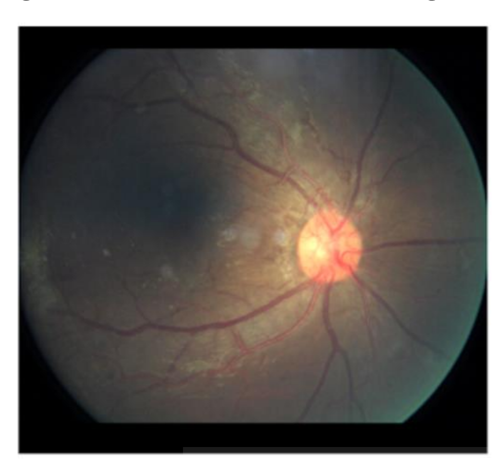
Algunos de los proyectos en los que se encuentra involucrados son los siguientes:

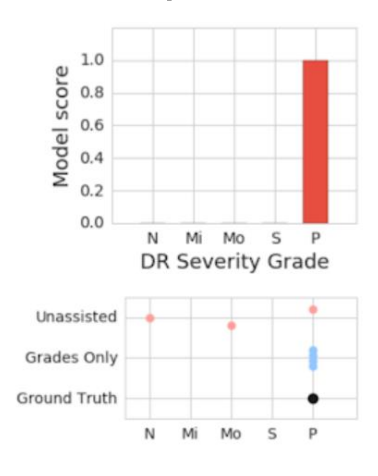
- **Diagnóstico de diabetes ocular.** La retinopatía diabética es la causa que avanza más rápido respecto de enfermedades prevenibles que pueden causar ceguera en forma permanente. El diagnóstico es dado, generalmente, por un profesional altamente formado en evaluaciones de retina. Si se detecta en forma temprana, existen tratamientos disponibles. Caso contrario, la enfermedad puede progresar hasta llegar a la ceguera. Dado que no existen tantos profesionales para cubrir el aumento de la demanda, Google ha desarrollado un sistema, basado en la visión y ML, capaz de leer las imágenes obtenidas de la retina. En las pruebas de eficacia realizadas al algoritmo, se ha alcanzado una precisión entre el 96% y el 97,5% (Sayres, 2018).

Universidad de SanAndrés

24. Para más información: https://ai.google/healthcare/

Figura 15. Resultados de diagnóstico de retinopatía ocular.





Ref. A la izquierda: una imagen de fondo de ojo clasificada como retinopatía diabética proliferativa. Arriba a la derecha: ilustración de la puntuación del modelo basado en DL, siendo 'P'= proliferativo. Abajo a la derecha: *Unassisted* hace referencia al diagnóstico brindado por tres médicos sin asistencia de la herramienta. Mientras que *Grades Only* hace referencia al diagnóstico brindado por tres médicos utilizando la asistencia de la herramienta. - Fuente: *Google Blog: Improving the Efectiveness of Fiabetic Retinopathy Models* (Sayres, 2018).

- **Asistencia al patólogo para detección de cáncer**. Analizar e informar la anatomía patológica es una tarea que requiere muchos años de entrenamiento. Incluso habiendo pasado por ese proceso, existe una posibilidad importante de que dos patólogos informen de distinta forma un mismo estudio. Por ejemplo, el acuerdo entre dos patólogos para algunas formas de cáncer de mama puede llegar a ser menor al 48%, de igual forma que para el cáncer de próstata. Esto no es tan sorprendente dada la gran cantidad de información que tienen que analizar para llegar al diagnóstico más certero. Para esto, Google creó, utilizando los beneficios de ML, un algoritmo automático de detección de estas patologías. A través del mismo, la predicción del mapa de calor alcanzó un 89% en el *FROC*[25], una mejoría significativa al 73% promedio para un patólogo sin limitaciones de tiempo (Stumpe, 2017).

25. Free Operating Characteristic (FROC) es un método de evaluación de *performance* de un diagnóstico. Para más información: https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2776072/

2.6.2 Apple

El caso de Apple es llamativo ya que, ser la compañía más grande en el mercado de capitales, con una valuación, al año 2018, de $1 trillón de dólares, no la exime de encontrarse extremadamente vulnerable dado que no se ha involucrado en tanto proyectos basados en IA como sí lo han hecho otras grandes compañías. A pesar de esto, Apple continúa teniendo una fuerte posición y podría modificar el mercado de IA, aprovechando la lealtad de sus clientes, su base de 1 billón de iphone funcionando, su billón de consultas realizadas a Siri por semana, una tienda (Apple Store) con más de 500 millones de visitas a la semana, y más de $270 billones de dólares para invertir (Porter, 2019).

Más allá de esto, al día de hoy, Apple basó sus esfuerzos en mantener y atraer nuevos usuarios a su ecosistema. La ausencia de herramientas estandarizadas para el desarrollo de terceros genera a Apple una oportunidad. Es por eso que la compañía es una de las que impulsa el protocolo FHIR[26] (Fast Healthcare Interoperability Resources). A diferencia de empresas como Google y Microsoft, el enfoque adoptado por Apple concibe a FHIR de manera tal que pueda ser capitalizado por sus usuarios, pudiendo descargar su historia clínica desde los prestadores de salud que utilicen dicho protocolo y se encuentren integrados al ecosistema de la compañía (Jindal, 2019).

La mayor experiencia de Apple está basada en cómo integrar de manera armónica el hardware y el software. Con esta fortaleza como base, la compañía centra sus esfuerzos en su aplicación de iPhone, Apple Health Record (en adelante, AHR). Con AHR, Apple busca posicionar a su historia clínica en el centro de la escena, algo que ya supo intentar Google, con su proyecto Google Health, el cual fue cerrado en 2012 (Dolan, 2011). La compañía ya ha realizado acuerdos con más de

26. FHIR fue creada para aumentar la interoperabilidad entre hospitales, profesionales y otras partes interesadas. FHIR crea estándares de manera tal que los desarrolladores puedan crear API´s que puedan ser utilizadas para acceder a datos de diferentes sistemas (Porter, 2019).

300 instituciones en Estados Unidos (Apple, 2019). Por otro lado, brinda un ecosistema amigable para terceros. *Startups* como Butterfly Network[27](ecógrafo portable), AliveCor[28](electrocardiograma portable) y Cellscope[29] (otoscopio digital) ya se han sumado a esta iniciativa. Con AHR, Apple intenta garantizar aumentos en la venta de dispositivos, como así también de sus servicios (Apple Cloud, Apple Store) (Porter, 2019).

Por otra parte, Apple ha adquirido, en 2017, la empresa Lattice por $200 millones de dólares (Lunden, 2017) La misma utiliza ML para convertir datos no estructurados a estructurados. Asociado a esto, se estima que entre el 70% y el 80% de los datos digitales existentes son no estructurados (Rogers, 2019).

2.6.3 Microsoft

La empresa de Redmond parece estar convencida que tecnologías como IA y la nube serán fundamentales en la transformación de la industria de la salud en los próximos años. Alineado a esto, en un sólo año ha aumentado su dotación de empleados orientados a IA en un 60%, pasando de ser 5.000 a 8.000 (Bishop, 2017).

En 2019, la compañía ha generado ingresos por más de $100 billones de dólares. Su CEO, Satya Nadella, justifica dichos ingresos a las inversiones realizadas en IA, sobre todo en sus servicios en la nube (Azure, Office 365, Dynamics 365, entre otros). La nube es el ecosistema utilizada por terceros para desarrollar sus proyectos de IA (Porter, 2019). Parte de esos clientes son hospitales, dado que actualmente ya utilizan el sistema operativo Windows. Este punto mencionado, sumado a que Azure cumple con las normas de seguridad de la información

27. Para más información: https://www.butterflynetwork.com/

28. Para más información: https://www.alivecor.com/

29. Para más información: https://www.cellscope.com/

HIPAA[30], hacen que sea lógico optar por este servicio en la nube como primera opción (Huynh, 2019). Por otro lado, para 2025, 90% de los hospitales en Estados Unidos utilzarán IA para salvar vidas y mejorar la calidad en la atención (Arsene, 2018).

En 2107 Microsoft crea su iniciativa *Healthcare NExT*. Está nueva división tiene como objetivo acelerar la innovación en salud a través de la IA y los servicios de Azure a través de investigaciones propias o en acuerdo con terceros (Beaver, 2018). Actualmente son 22 las compañías que se encuentran en alianza con Microsoft en el desarrollo de soluciones de IA para la salud (Huynh, 2019).

Algunos de los proyectos en los que se encuentran trabajando son:

- **InnerEye.** El proyecto, apoyado en técnicas de visión y ML, realiza una marcación automática de tumores y anatomía sana en imágenes en 3D. A su vez, permite la extracción de mediciones, contornos eficientes para la planificación de la radioterapia y planificación precisa para cirugías (Microsoft, 2018).
- **Search Algorithms to predict lung cancer.** Partiendo con la premisa que la gente tiende a ingresar sus síntomas y preocupaciones respecto a su salud en los motores de búsqueda web, se ha desarrollado esta investigación. A través de ML, se intenta comprender cuáles son los factores de riesgo para padecer cáncer de pulmón. No solo se utiliza el texto de las búsquedas sino que también se tiene en cuenta información como la ubicación (código postal) desde donde se realiza la consulta, demografía o genero (Roach, 2016).

En los años 2013 y 2017, Microsoft alcanzó las 73 patentes. La mayor parte de las mismas se encuentran orientadas a IA y telemedicina (Licking et al., 2018).

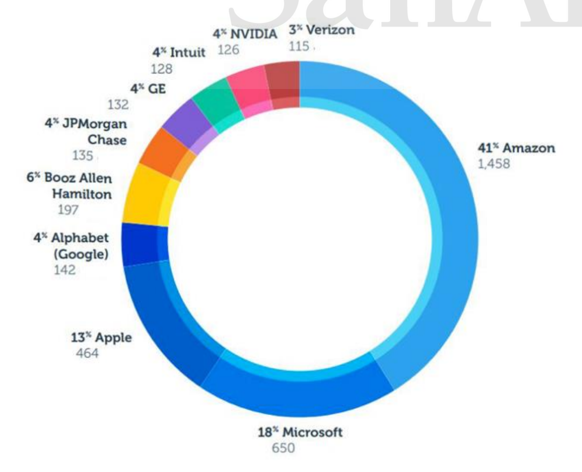
30. HIPAA es el acronismo de Health Insurance Portability and Accountability Act. HIPAA realiza, entre otras cosas el requerimiento de la protección y del uso confidencial de la información relacionada a la salud de las persona.

2.6.4 Amazon

Como lo escribió su CEO, Jeff Bezos, en una carta a sus accionistas, la IA y ML son de suma importancia para Amazon, siendo las mismas, parte del corazón de sus negocios principales. Amazon se encuentra creciendo entre un 20% y 30% anual, teniendo para 2017, $178 billones de dólares de ganancias provenientes de sus más de 300 millones de usuarios activos y aproximadamente 500 millones de productos. Por otro lado, ha alcanzado una cobertura del 44% del mercado de comercio electrónico en Estados Unidos, siendo, por amplia diferencia, el proveedor más grande de ese país (Porter, 2019).

A diferencia de compañías como Google y Facebook, Amazon se encuentra más interesada en resolver problemas inmediatos o innovar en nuevas tecnologías basadas en IA, que en realizar investigación clásica. Esto ha hecho que la compañía tenga una reputación de ser menos orientada a la investigación y la academia. Amazon se posiciona como el reclutador más grande del mundo de talentos con conocimientos en IA (Porter, 2019).

Figura 16. Top 10 de empresas con mayor reclutamiento de ingenieros especializados en IA.



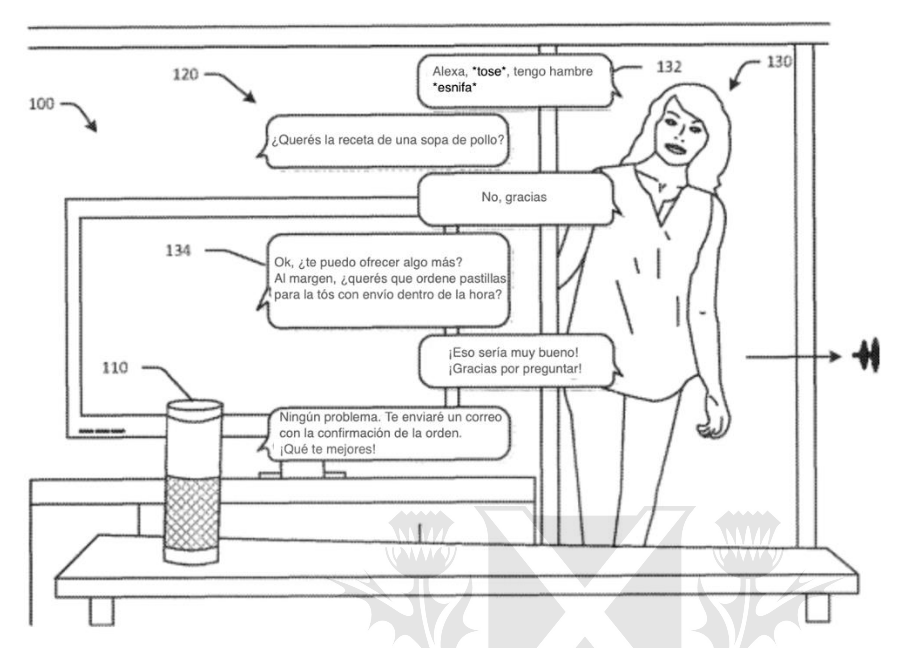
Ref: Amazon es la empresa que con mayor contratación de ingenieros con conocimientos en IA (1458 personas). El podio lo completan Microsoft (650 empleados) y Apple (464 empleados). - Fuente: *The Top Acquires in Artificial Intelligence* (Porter, 2019).

Al igual que compañías como Google, Amazon creó internamente un equipo interno, llamado *Grand Challange*. El objetivo de este equipo es el de explorar nuevas oportunidades para ampliar el negocio de la compañía. Dentro de dichas oportunidades se encuentran las vinculadas a salud. Si bien no hay mucha información a respecto, el equipo se encuentra trabajando en proyectos vinculados a la detección temprana y cura del cáncer (Kim, 2018).

En el ámbito de la salud, el principal proyecto en el que se encuentran trabajando tiene por nombre *Amazon Comprehend Medical*[31]. Haciendo provecho del poder de procesamiento de su plataforma *Amazon Web Services*, y utilizando ML, el servicio utiliza PLN para decodificar la información no estructurada escrita en historias clínicas digitales y notas de profesionales médicos. Identificar enfermedades, medicaciones y dosis, detalles de evaluaciones médicas, tratamientos, procedimientos, son algunas de las posibilidades que ofrecer esta herramienta. A la par, Amazon se encuentra trabajando en ampliar las capacidades de su servicio de asistente virtual inteligente, Alexa. La nueva funcionalidad utilizará análisis de voz para reconocer signos de enfermedad o emociones.

31. Para más información: https://aws.amazon.com/es/comprehend/medical/

Figura 17. Caso de uso de patentado por Amazon.



Ref: El caso de uso patentado muestra a una mujer realizando una consulta a Alexa mientras tose y se suena la nariz. Alexa responde la pregunta y sugiere ordenar un medicamento para la tos (Spanu, 2019). Dicho medicamento será enviado por Amazon, quien en 2018 anunció la adquisición de Pill Pack, una de las farmacias *on line* más importantes de Estados Unidos por $753 millones de dólares (Farr, 2019). - Fuente: Elaboración propia a partir de (Spanu, 2018).

2.6.5 Facebook

Con el objetivo de construir el mejor laboratorio de IA del mundo, Facebook contrata en 2013 a Yann LeCun, uno de los pioneros en el diseño y uso de RNC, como director del área de Investigación en IA (FAIR por su nombre en inglés, *Facebook Artificial Intelligence Research*). Como ya hemos mencionado, las oportunidades en IA crecen mientras se tenga grandes cantidades de datos a analizar. Alineado a esto, Facebook cuenta, al año 2019, con 2,2 billones de usuarios mensuales activos, de los cuales apenas le está sacando el provecho que tamaña muestra puede generar. Actualmente su ARPU[32] mundial es de $5,97 dólares. Por otro lado, el ARPU en Estados Unidos y Canadá es de $25,91 dólares. En ambos casos hay grandes oportunidades para hacer crecer dichas cifras (Porter, 2019).

32. Promedio de ganancia por usuario.

A través de la IA, Facebook tiene la oportunidad de potenciar sus productos insignia (Facebook, Instagram, Whatsapp, entre otros) y expandirse a otras verticales, como ser salud, *retail* o servicios para empresas. Prácticamente todo lo que el usuario puede visualizar en Facebook está atravesado por IA y ML. Algunas de las tecnologías comúnmente utilizadas hoy son las tecnologías del lenguaje (traducciones, reconocimiento de voz, comprensión de lenguaje natural), filtro de contenidos (reducción de artículos no deseados, noticias falsas, discursos con incitación al odio), visión (su algoritmo de reconocimiento facial posee una precisión del 97% (contra una precisión del 85%, que posee el FBI)) y publicidad (dónde y cuándo mostrarla, maximizando la cantidad de clicks) (Porter, 2019).

En cuanto a sus adquisiciones, desde 2015, Facebook ha adquirido 17 empresas. La mayor parte de estas utilizan algún tipo de IA. (Porter, 2019).

Respecto a salud, la empresa se encuentra trabajando, en conjunto con del departamento de DPI de la escuela de medicina de la Universidad de Nueva York, en un proyecto denominado *fastMRI*. El mismo tiene por objetivo utilizar los beneficios de la IA para realizar el proceso de obtención de imágenes en un resonador, diez veces más rápido, sin pérdida de información alguna. Las resonancias, a diferencia de la mayor parte de las modalidades, llevan un tiempo mayor, que puede ir entre 15 minutos a una hora. Por este motivo, sumado a que es necesario que el paciente no se mueva durante el estudio, el proceso puede ser dificultoso en su implementación. Sobre todo para algunos grupos, como niños, ancianos y pacientes con algún tipo de discapacidad (Middleton, 2018).

Uno de los desafíos que tendrá Facebook, para poder continuar el camino en el terreno de la salud, es volver a lograr la confianza de sus usuarios respecto a la privacidad de la información. La pérdida abrupta de la misma se origina en 2017 con el escándalo de Cambridge Analytica, en donde 87 millones de cuentas de Facebook fueron impactadas en una operación que tuvo como objetivo influir en los

resultados de las elecciones presidenciales del 2016 en Estados Unidos (Porter, 2019).

2.6.6 IBM

IBM provee productos y servicios a las empresas más grandes del mundo, 95% de las mismas componen el listado de, gran cantidad de bancos y proveedores de comunicación (Porter, 2019). La compañía se encuentra trabajando en el campo de la IA ya por décadas. Como hemos mencionados anteriormente, en 1997, Deep Blue, consigue vencer al campeón del mundo de ese momento Garry Kasparov, en un torneo de 6 partidas[33]. En 2011, se desarrolla Watson, plataforma de IA orientada, entre otro aspecto, a mejorar los procesos de negocio, mejorar los modelos de datos, acelerar los procesos de investigación y mejorar la interacción con clientes (Porter, 2019). La primera aparición de Watson se dio en el show de televisión, *Jeopardy!* En el mismo, compite, como un participante más, contra dos campeones del programa, ganándoles a ambos y quedándose con el primer puesto (Max Tegmark, 2017).

Watson fue concebida para responder preguntas, haciendo uso de PLN, IA, representación de conocimiento, razonamiento automatizado y ML. Luego, sus formas de uso se fueron ampliando. En 2013, Watson hace su debut comercial en el campo de la salud. Su utilización se basó en la ayuda en la toma de decisiones en el tratamiento del cáncer de pulmón. Se pueden destacar los siguientes proyectos:

- **Imaging Clinical Review**. Esta herramienta tiene por objetivo crear un registro de paciente más confiable y mejorar la calidad de reportes y procesos de facturación. Imaging Clinical Review mejora el proceso, desde el diagnóstico hasta la documentación, eliminando la pérdida de información, utilizando para esto: lectura de datos estructurados y no estructurados,

33. Para más información: https://en.wikipedia.org/wiki/Deep_Blue_versus_Garry_Kasparov

comprendiendo los datos para obtener información significativa, comparando la información que se desea dejar asentada de estudios o atención con los diagnósticos almacenados en la historia clínica electrónica (Le Grand, 2017).

- **Watson por Oncology**. Este desarrollo toma como entrada la información de pacientes (laboratorios, historia clínica, entre otros), y la contrasta con literatura médica y otra información con el fin de realizar recomendaciones para el tratamiento (Selanikio, 2018).
- **Image Patient Synopsis**[34]. Los médicos especialistas en DPI consumen un tercio de su tiempo informando imágenes (IBM, 2018). Muchas veces las imágenes tienen un grado de complejidad mayor y para ser más preciso, el diagnóstico debe realizarse teniendo en cuenta información de la historia clínica electrónica, la cual está compuesta, en su mayoría, por información no estructurada. Por tal motivo, la misma muchas veces no es tenida en cuenta. La herramienta permite, integrándose con el PACS[35], extraer información valiosa de la historia clínica del paciente y presentarla al profesional como soporte para la toma de decisión más eficiente. La información que se tiene en cuenta es la referida a enfermedades previas, consultas realizadas, medicamentos, historia familiar, demografía, alergias, laboratorios e indicaciones prescriptas.

Porfundizando su participación en DPI, IBM ha adquirido en 2015 la compañía Merge Healthcare, proveedora de un software de DPI. La misma cuenta con una base de datos de 30 billones de imágenes de pacientes, escenario ideal para la realización de entrenamientos de redes neuronales (Wang, 2016).

A continuación, haremos una introducción a la especialidad médica en la que se enfoca nuestra tesis, el DPI. Para eso, definiremos a la misma, haremos un repaso

34. Para más información: https://www.ibm.com/downloads/cas/NEA3YYQN

35. PACS son las siglas de *Picture Achiving and Communication System*. Se trata de sistemas de almacenamiento y distribución de imágenes médicas. Para más información: https://pubs.rsna.org/doi/pdf/10.1148/radiographics.12.1.1734458

de sus primeros pasos y describiremos las modalidades más utilizadas. Luego, haremos una clasificación de las herramientas de soporte para detección y diagnóstico. Por último, describiremos a la teleradiología, técnica que cambió radicalmente la forma de realizar el diagnóstico por imágenes.

2.7 Diagnóstico por Imágenes

El DPI es una especialidad médica que, valiéndose de distintos tipos de tecnologías (rayos x, ultrasonido, campos magnéticos, entre otras) produce imágenes médicas, las cuales son utilizadas para detectar, diagnosticar y tratar enfermedades. La especialidad comienza siendo únicamente de diagnóstico. Es decir, interpretar las imágenes que han sido resultado del uso de las distintas modalidades[36]. Con el tiempo surge el intervencionismo, rama del DPI que utiliza técnicas poco invasivas para proveer una amplia cantidad de procedimientos terapéuticos utilizando a las imágenes como herramienta de guía. Generalmente se utilizan como soporte fluroscopías, ultrasonido y tomografías. En el pasado, muchos casos requerían una cirugía compleja. Actualmente pueden ser realizadas a través de pequeñas incisiones en la piel utilizando catéteres e instrumental muy pequeño. El rango de procedimientos y órganos tratados por los médicos especialistas en DPI es extenso e incluye todo lo referido a enfermedades vasculares, gastrointestinales, hepatobiliares, renales, musculoesquelético, pulmonar y neurológica, cánceres o tumores, entre otros (Seyed Ameli Renani & Belli, 2014). Es por esto que no todos los profesionales pueden subespecialisarse en una región del cuerpo o tipo de procedimiento.

En Estados Unidos, un típico especialista en DPI invierte, aproximadamente, entre 14 y 15 años de educación. Esto incluye, 4 años de facultad, 4 años de escuela de

36. Se refiere al equipo a través del cual se realiza la generación de imágenes. Por ejemplo, el tomógrafo (Thurston & Bell, 2019).

medicina, 1 año de internado, 4 años de residencia en DPI, y generalmente entre 1 y 2 años de *fellowship* a modo de entrenamiento (Mazurowski et al., 2018).

Además del médico especialista, existen otros dos roles que intervienen en el proceso de la especialidad: los enfermeros y los técnicos en DPI. El enfermero es quien tiene por objetivo el cuidado del paciente en los momentos previos y posteriores de la realización del estudio, la administración de medicamentos, contrastes, como así también el monitoreo de signos vitales. El técnico en DPI es el encargado de ejecutar el estudio y generar las imágenes en cada una de las distintas modalidades. Algunas veces también son los encargados de tomar mediciones de las imágenes, las cuales serán utilizadas luego por el profesional para generar el informe (RadiologyInfo.org, 2019).

De cada estudio realizado debe desprenderse un informe. El informe es el documento que contiene el detalle de la interpretación oficial que realizó el médico sobre la examinación o el procedimiento. El informe debe ser preciso, conciso y pertinente. Esto debe ser así para evitar la mala interpretación del médico o el paciente que lo lea. Pero también debe tener esas características ya que el mismo es un documento médico legal. Y su contenido, al ser tan sensible en muchos casos, puede resultar causal de un caso de mala praxis (Wallis & Mccoubrie, 2011).

2.7.1 Evolución del Diagnóstico por Imágenes

La historia de la especialidad comienza en 1895 a través de Wilhelm Roentgen, ingeniero mecánico y físico alemán, quien produce y detecta radiación electromagnética en una longitud de onda, la cual denominó, rayos X. Este descubrimiento le valió a Roentgen el premio Nobel de física en 1901 (Dunn, 2001). Luego de este descubrimiento, no estaba del todo claro cuáles iban a ser todos los usos que se le iban a dar a la tecnología. Pero la aplicación en la medicina tardó poco en llegar. En 1900 se forma la Sociedad Americana Roentgen Ray, como un

intento de establecer a la radiología[37] como una especialidad médica y de desarrollar estándares para el uso de los rayos X. En 1906, la misma agrupación autorizó el lanzamiento de la *American Quarterly of Roentgenology*, siendo su primer editor el Dr. Preston Hickey (Gagliardi, 1990). Hickey utilizó los subsiguientes diez años esa publicación periódica como el medio para desarrollar la radiología como una especialidad médica que sea reconocida por el mundo de la salud. Entre sus aportes, Hickey crea el término "interpretación" de radiografías como el proceso que involucra conocimiento especializado en el que un diagnóstico diferencial de los hallazgos radiográficos podría llevar a una conclusión basada en probabilidades (Wallis & Mccoubrie, 2011).

En sus comienzos, las radiografías eran realizadas en platos fotográficos de vidrio. En 1918, George Eastman, fundador de la empresa Kodak, crea el papel film radiográfico, lo que genera un cambio radical en la forma de generar y almacenar imágenes médicas (Haus & Cullinan, 2013).

QUAERERE VERUM
Universidad de SanAndrés

2.7.2 Modalidades

Si bien los rayos X fueron la primera técnica de diagnóstico utilizada en la especialidad, a través de los años se fueron sumando nuevas técnicas. A continuación, en base a la definición del *National Institute of Biomedical Imaging and Bioengenieering*, definiremos a los rayos X, el ecógrafo, el tomógrafo computado y el resonador magnético.

2.7.2.1 Rayos X

Se trata de una radiación electromagnética, la cual posee la capacidad de pasar a través de gran parte de los objetos y del cuerpo humano. En DPI se utiliza para generar imágenes de tejidos y estructuras dentro del cuerpo. Esto es posible ya que,

37. La especialidad, en sus comienzos, era denominada Radiología, ya que los Rayos X fueron la primera tecnología utilizada para el diagnóstico. En otros países, como por ejemplo Estados Unidos, se continua utilizando "*Radiology*" en referencia a la especialidad en su conjunto.

al atravesar el cuerpo, también lo hacen a un detector de rayos X, proyectando en el mismo una “sombra”. Dicho detector de rayos X puede ser el ya mencionado film fotográfico. Pero también existen tecnologías para generar imágenes digitales. En cualquiera de los casos, el resultado es la radiografía.

Los rayos X suelen utilizarse en las siguientes formas:

- Equipo convencional de rayos X: utilizado para detectar fractura de huesos, alguna clase de tumor o de lesión, calcificaciones, entre otros casos de uso.
- Mamografía: consta de una radiografía de las mamas, la cual es utilizada en detección y diagnóstico de cáncer.
- Tomografía. Explicado más adelante en la sección “Tomógrafo Computado”

2.7.2.2 Ecógrafo

El ecógrafo es una modalidad diagnóstica y funcional. La tecnología utilizada es la de ultrasonido. La misma utiliza ondas sonoras de alta frecuencia para caracterizar el tejido. El equipo envía pulsos de ultrasonido (llamadas transductores) al tejido, el cual recibe luego un eco. Ese eco contiene información de espacio y contraste.

Si bien, la mayor parte de las sondas de ultrasonido se utilizan en forma externa, existen sondas que se introducen dentro del cuerpo (tracto gastrointestinal, vagina, entre otros) para mejorar la calidad de la imagen.

El ultrasonido puede caracterizarse en dos tipos, diagnóstico y funcional.

- **Diagnóstico**. Se utiliza comúnmente para monitorear el crecimiento y desarrollo del feto durante el embarazo, generar imágenes de corazón, vasos sanguíneos ojos, tiroides, cerebro, músculos, entre otros. Las imágenes pueden ser en 2D, 3D o 4D (imágenes 3D con movimiento).

- **Funcional**. Se utiliza para realizar Doppler[38], medir velocidad de flujo sanguíneo, entre sus usos más comunes.

Figura 18. Ecógrafo.



Fuente: Samsung Health Care.

Figura 19. Tomógrafo computado.



Fuente: Siemens Healthinners.

2.7.2.3 Tomógrafo Computado

El tomógrafo computado (CT, por sus siglas en inglés) emplea un procedimiento en el que se proyecta un haz angosto de rayos X sobre el paciente y se gira rápidamente alrededor del mismo. Esto genera señales, las cuales son procesadas para generar imágenes transversales del cuerpo, en 2D. El tomógrafo genera tantos cortes transversales tales que al agruparlos puede generar una imagen en 3D. Esto sirve para ubicar estructuras básicas, tumores o anormalidades.

Dado que algunos tejidos blandos no son visibles por los rayos X, algunas tomografías se realizan con algún medio de contraste. Los contrastes tienen la

QUAERERE VERUM Universidad de SanAndrés

38. La ecografía Doppler es una prueba no invasiva que calcula el flujo de la sangre en los vasos sanguíneos haciendo rebotar ondas sonoras de alta frecuencia en los glóbulos rojos circulantes. En la ecografía común, se utilizan ondas sonoras para crear imágenes, pero no se puede mostrar el flujo sanguíneo (Sheps, 2016).

característica de ser visibles por un escaneo de tomografía. Yodo y bario son algunos de los medios que se utilizan para generar la imagen en forma correcta.

Una de las subespecialidades que más uso hace de la tomografía es la Medicina Nuclear. Esta se vale del uso de radiofármacos suministrados, generalmente, a través de vías endovenosas u en forma oral, para evaluar funciones corporales. Las dos modalidades más comunes son:

- **Tomografía Computarizada por Emisión de Fotón Único** (SPECT, por sus siglas en inglés). Los escaneos del tomógrafo poseen detectores de cámara gamma, los cuales pueden detectar las emisiones de rayos gamma de los radiofármacos suministrados. Se utiliza generalmente para diagnosticar y controlar el avance de las enfermedades del corazón.
- **Tomografía por Emisión de Positrones** (PET, por sus siglas en inglés). Producen partículas llamadas positrones, las cuales poseen la misma masa que el electrón, pero con carga positiva. Esto genera una reacción en el cuerpo cuando ambas partículas se combinan generando dos fotones que se disparan en direcciones opuestas. El escaneo mide los fotones y a través de los mismos genera las imágenes de los órganos. Se utiliza generalmente para detectar cáncer, monitorear su evolución, respuesta a tratamientos y metástasis.

2.7.2.4 Resonador Magnético

El resonador magnético (MRI, por sus siglas en inglés), al igual que el tomógrafo computado, produce imágenes 3D pero sin la utilización de rayos X. El resonador estimula y detecta el cambio en la dirección del eje de rotación de protones, los cuales se encuentran en el agua que compone los tejidos vivos. A través de grandes imánes se genera un campo magnético que obliga a los protones a alinearse a éste. Cuando se pulsa una corriente de radiofrecuencia, a través de un paciente, los protones son estimulados y giran fuera de equilibrio, luchando contra la fuerza del

campo magnético. Al finalizar la corriente, el resonador detecta la energía liberada mientras los protones vuelven a alinearse. A menudo se utiliza algún tipo de contraste para modificar la velocidad en que los protones se realinean. Cuanto más rápido suceda esto, más brillante será la imagen. Cerebro, médula, músculos, tendones, son ejemplos de partes del cuerpo que se ven significativamente mejor en una resonancia magnética que en una tomografía o en una radiografía.

Figura 20. Resonador magnético.



Fuente: Siemens Healthinners.

A continuación, realizaremos una explicación de la práctica de análisis de imágenes a distancias, más conocida como teleradiología.

2.7.3 Teleradiología

La teleradiología es un servicio mediante el cual se transmiten en forma electrónica las imágenes médicas desde un centro de diagnóstico, clínica u hospital hacia otra ubicación, para la realización del diagnóstico y la confección del informe. Su surgimiento se da como una solución al creciente problema que surge de:

- Una mayor demanda de realización de estudios.
- La subespecialización del DPI.
- La falta de médicos especialistas en DPI, cada vez más por debajo de la necesidad del mercado (Ramirez, 2009).

Universidad de SanAndrés

Con los avances de las telecomunicaciones, y de cada vez más herramientas tecnológicas, es posible dar respuesta a este escenario con una puesta en producción de bajo costo (Ramirez, 2009).

Como aspectos positivos de la teleradiología se pueden destacar:

- Contar con especialistas en las distintas regiones del cuerpo, las 24 horas del día.
- La posibilidad de realizar una interconsulta médico - médico para obtener una segunda opinión acerca de un diagnóstico.
- Instituciones pequeñas y alejadas puedan tener diagnósticos especializados y de calidad.
- No es necesario contar con un médico especialista en el centro de diagnóstico. La solicitud de informe se puede realizar a demanda, mejorando las condiciones en las que el profesional ejerce su tarea (Silva III et al., 2013).

Por otro lado, como aspectos negativos de la teleradiología e destacan:

- *Comoditización* del trabajo del especialista en DPI. El foco se pone únicamente en una mirada financiera, en donde la variable predominante es la producción en cantidad de informes médicos, ignorando el rol del médico como un experto que ocupa un lugar importante en el equipo de trabajo dedicado a un paciente.
- Pérdida de trabajo de médicos especialistas en DPI. En la medida que grandes grupo de teleradiología avancen sobre centros pequeños y medianos, ofreciendo costos propios de un negocio de alto volumen, los profesionales locales se podrán ver afectados en sus condiciones laborales, pudiendo llegar a la pérdida del empleo (Krupinski, 2013).

A continuación, realizaremos una definición de los distintos casos de uso en donde se puede implementar soluciones de ML en un área o centro de DPI.

2.7.4 Casos de Uso de Machine Learning en un centro de DPI

ML posee el potencial de ser aplicada a cada etapa del flujo de trabajo de un área o centro de DPI, generando mejoras en la eficiencia de sus operaciones y ahorros de dinero para los proveedores de salud, a la par de diagnósticos más rápidos y precisos (Harris, 2018c).

Las etapas de un área o centro de DPI son las siguientes: turnos, adquisición de Imagen, análisis de imágenes, reportes, plan de tratamiento y seguimiento.

A continuación, según el informe realizado por Harris (2018c) listaremos los casos de uso que se pueden aplicar a cada una de las mismas.

Turnos

- Predicción de cancelaciones de turnos y ausentismo.
- Seguimiento de nuevos turnos en base a hallazgos en estudios ya realizados.

Adquisición de imágenes

- Protocolo automático de selección de imágenes y posición correcta del paciente. Ambos generan menor repetición de escaneos, ahorrando tiempo para el paciente y el prestador. En caso de que el estudio sea de rayos X o tomografía, se logra evitar exposiciones innecesarias de radiación.
- Reconstrucción de imágenes. Permite utilizar menor cantidad de contraste y reducir la exposición del paciente a la radiación.
- Análisis de resonancias. Permite evitar secuencias de imágenes innecesarias en caso de no encontrar nada en las primeras secuencias. Permiten reducir el tiempo de estudio y evitar el potencial uso de contraste.

QUAERERE VERUM
Universidad de
SanAndrés

Análisis de imágenes

- Triage automático. Permite realizar un análisis inicial a través del cual se pueden priorizar la lectura de los estudios anormales, generando diagnósticos más rápidos y precisos.
- Detección, segmentación y cuantificación de características. Si ML encuentra una anormalidad, brindará una probabilidad de malignidad o un diagnóstico diferenciado.
- Flujo de trabajo. Una vez que el profesional abre un nuevo caso, ML buscará cualquier estudio previo que sea relevante y dará información y herramientas que permitan su correcta gestión.

Reportes

- Generación automática de reportes. ML puede generar un pre-reporte con resultados cuantitativos y hallazgos, permitiendo al profesional aprobarlos o editarlos.
- Calidad. Una vez realizado el reporte, la IA se asegura que todos los hallazgos hayan sido reportados con precisión y que nada se haya pasado por alto.

Universidad de SanAndrés

Plan de tratamiento y seguimiento

- A través de la automatización de tareas manuales de medición se mejora la precisión en el diagnóstico y en el tratamiento, generando planes personalizados para cada uno de los pacientes.
- Soporte en la toma de decisiones para planes de tratamiento. Esto se realiza haciendo uso de resultados de pacientes que hayan tenido enfermedades con características similares. En consecuencia, se puede contar con planes de tratamiento más cortos, potencialmente eliminando iteraciones, generando así, ahorros de tiempo y dinero.

A continuación, realizaremos una definición de los sistemas de detección y diagnóstico asistidos por computadora.

2.7.5 Detección y Diagnóstico Asistido por Computadora

CAD (por su nombre en inglés, Computer-Aided Detection and Diagnosis), es un tipo de sistema informático utilizado como "segunda opinión" en la detección y diagnóstico de enfermedades. CAD es un término que se ha comenzado a utilizar entre la década del 80 y del 90, en la llamada segunda era de la IA (Oakden-Rayner, 2019).

El objetivo de los sistemas CAD es mejorar la precisión de los resultados generados por los médicos especialistas en DPI, como así también generar una reducción en el tiempo utilizado para interpretar las imágenes (Firmino, Angelo, Morais, Dantas, & Valentim, 2016).

Los sistemas CAD, generalmente, se clasifican en dos grupos:

- **Detección Asistida por Computadora (CADe).** Son aquellos sistemas que identifican características sospechosas en las imágenes, con el objetivo de enfocar el análisis del médico, evitando así falsos negativos (Castellino, 2005).
- **Diagnóstico Asistido por Computadora (CADx).** Son aquellos sistemas que generan una caracterización de las lesiones. Por ejemplo, la distinción entre un tumor benigno con uno maligno (Firmino et al., 2016). En cuanto a la regulación, La FDA ha clasificado a las CADx como de mayor riesgo respecto a las CADe (Oakden-Rayner, 2019).

Hasta el surgimiendo de DL, las CAD utilizaron técnicas que provienen del procesamiento de imágenes y extracción de características, También clasificadores básicos de ML, como ser *Support Vector Machine*, *RN Shallow, Random Forrest*, entre otras técnicas (E. Ferrante, comunicación personal, 1 de Julio de 2019).

La utilización de CAD, en Estados Unidos, llegó a ser masiva para algunos tipos de estudios. Por ejemplo, se estima que en 2010, más del 74% de las mamografías fueron analizadas con la asistencia de herramientas CAD (Oakden-Rayner, 2019).

Pero el éxito de estas herramientas no fue tal y su uso fue dejando de lado. Estudios realizados determinaron que las soluciones CAD no han aportado beneficios o, incluso, han reducido la precisión de los médicos. Esto ha ocasionado diagnósticos equivocados, traducido en una mayor repetición de estudios y mayor toma de muestras para la realización de biopsias. Podía ser usual que los sistemas CAD soliciten al médico el análisis de una gran cantidad lesiones inexistentes, algo que podía generar un sesgo en la toma de decisión del profesional. A este problema se le suma uno más, la ineficiencia. Se estima que con las herramientas CAD existió un aumento del 20% del tiempo utilizado para interpretar cada estudio, generado por la necesidad del médico de desestimar falsas alarmas generadas por los sistemas (Oakden Rayner, 2019).

Si bien, haciendo la aclaración de que existen CADe que funcionan en forma correcta, el Dr. Enzo Ferrante comparte que existió una ineficiencia generalizada en la impementación de las CADx. Pero que esto se comienza a revertir a partir de la implementación de DL (E. Ferrante, comunicación personal, 1 de Julio de 2019).

CAPÍTULO 3 – Machine Learning en Diagnóstico por Imágenes

A continuación, identificaremos por qué se está comenzando a usar DL en DPI, sus aplicaciones dentro de la especialidad y el impacto en el rol del profesional. Describiremos los aspectos éticos y regulatorios más importantes a la hora de implementar la tecnología. Finalmente caracterizaremos el mercado de ML en DPI y haremos mención de algunas de las *startups* más importantes. Por último, detallaremos la visión a futuro sugerida por la consultora Signify Research acerca del mercado de ML en el DPI.

3.1 ¿Es el momento de implementar Machine Learning en el Diagnóstico por Imágenes?

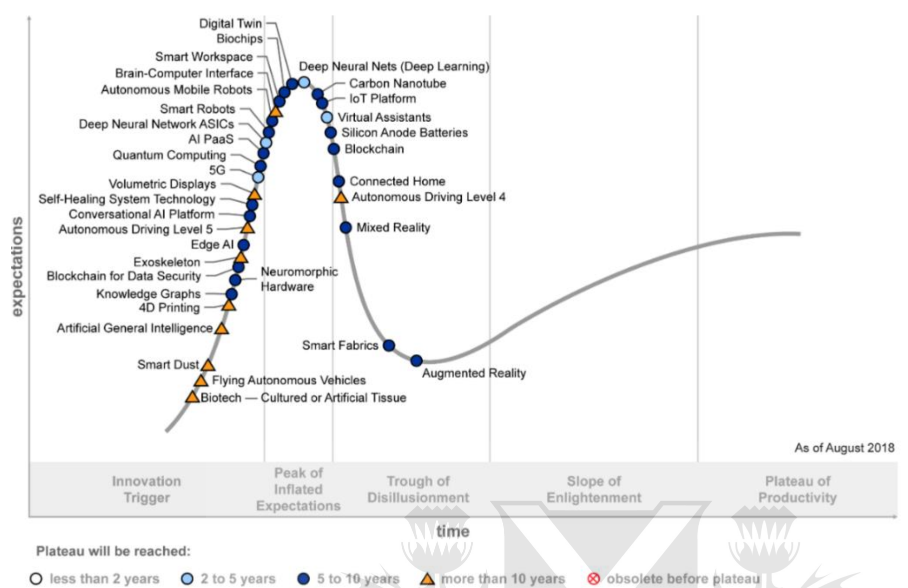
Dado el gran avance de proyectos en ML para DPI, detallaremos una serie de motivos por los cuales consideramos que esto está sucediendo. DL, avances en hardware y software, volumen de imágenes, proyectos para compartir imágenes, el DPI como una especialidad médica automatizable e innovadora, necesidad de generar escalabilidad, precisión en los resultados y ahorro de tiempos son, a nuestro parecer, los puntos más destacados a tener en cuenta.

3.1.1 La adopción de Deep Learning

Según la consultora Gartner, en su informe de 2018, *Hype Cylce for Emerging Technologies y Hype Cycle for Artificial Intelligence*, DL se encuentra en un momento de grandes expectativas, esperando que llegue a una etapa de madurez y adopción masiva en un lapso que va entre dos y cinco años. DL es la forma de ML por excelencia utilizada para solucionar problemas asociados al reconocimiento de imágenes. Es por este motivo que es tan popular en el área de DPI.

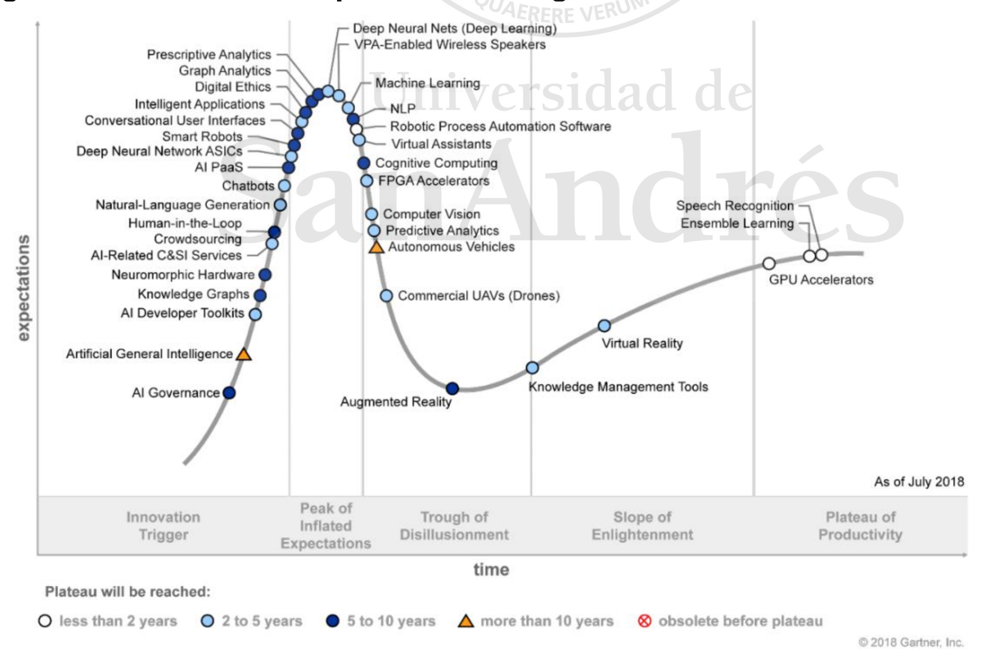


Figura 21. Curva de adopción de tecnologías emergentes.



Ref. En la curva de Gartner 2018 de tecnologías emergentes se encuentra DL presente con un horizonte de llegada masiva que va de los 2 a 5 años. Por otro lado, se denota la ausencia de ML. Fuente: *Hype Cycle for Emerging Technologies* (Gartner, 2018).

Figura 22. Curva de adopción de Inteligencia Artificial.



Ref. En la curva de Gartner 2018 de Inteligencia Artificial se encuentran tanto ML como DL, con un horizonte de llegada masiva que va entre los 2 y 5 años. - Fuente: *Hype Cycle for Artificial Intelligence* (Sicular & Brant, 2018).

3.1.2 Avances en Hardware y Software

A nivel de hardware, los algoritmos de DL han visto un gran avance en su velocidad. La razón principal es la Unidad de Procesamiento de Gráficos (en adelante, GPU). La misma, utilizada para visualizar gráficos en la computadora, puede utilizarse para realizar cálculos en los algoritmos de DL. La GPU generalmente tiene cientos o miles de unidades de procesamiento que realizan múltiples cálculos en forma simultánea. Gracias a esto, los algoritmos de DL pueden funcionar de diez a cien veces más rápido, comparado con un CPU tradicional.

Otro aspecto importante es que, de acuerdo a la ley de Moore[39], la memoria de placas de GPU crecen exponencialmente, lo cual hará de DL un proceso cada vez más eficiente (Erickson et al., 2018).

Respecto del Software, existen actuamente varios *frameworks* cuya finalidad es la construcción y el entrenamiento de RN multicapa, entre las que se encuentran las RNC. *Frameworks* como Theano, Torch, Tensorflow, CNTK[40], Caffe y Keras permiten implementar funciones de manera eficiente. Así, los desarrolladores pueden describir arquitecturas de RN con muy pocas líneas de código y enfocarse en los aspectos relacionados con la arquitectura a alto nivel. La mayor parte de estos frameworks son gratuitos y de código abierto (Chartrand et al., 2017).

3.1.3 Mayor disponibilidad de bancos de imágenes para entrenamiento

El DPI ha jugado un rol de liderazgo en el impulso de llevar a la medicina a la era digital. La IA le brinda la oportunidad de continuar ese liderazgo, explorando las aplicaciones que le puede dar al mercado de la salud. Millones de informes de estudios, billones de imágenes almacenadas en formato digital constituyen la base

39. Para más información: https://en.wikipedia.org/wiki/Moore%27s_law
40. Actualmente su nombre ha cambiado a *Microsoft Cognitive Toolkit*.

necesaria para el avance de DL. La disponibilidad de esa información es fundamental para realizar el entrenamiento de las aplicaciones (Thrall et al, 2017).

A nivel de investigación, es necesario analizar la mayor cantidad y variedad de imágenes. Para esto es fundamental contar con imágenes de diferentes instituciones. Esto se está logrando en Estados Unidos gracias a diferentes iniciativas. Existen actualmente redes creadas por la Sociedad Radiológica de Norte América (RSNA, por sus siglas en inglés) y el Colegio Americano de Radiología (ACR, por sus siglas en inglés), como así también bases de datos creadas para compartir imágenes, como el Archivo de Imágenes de Cáncer del Instituto Nacional del Cáncer[41] (Thrall et al, 2017).

3.1.4 DPI es una especialidad suceptible de ser automatizada

El Dr. Daniel Luna considera que hay especialidades médicas que tienen más posibilidades de traducirse en algoritmos. "En la medicina hay un modelo entre lo que podemos denominar, "muy algoritmizable" y "poco algoritmizable". Diagnóstico por imágenes y oftalmología, son ejemplos de "muy algoritmizable". En la otra punta se encuentra la especialidad de cirugía o enfermería, tareas muy difíciles de automatizar. En el medio se encuentra la medicina clínica, entre otras especialidades. Los especialistas en DPI entienden que parte de su especialidad es automatizable. Y es por eso que, ya gran parte de ellos se dieron cuenta que tienen que transformarse. Si no hacen parte del intervencionismo manual de los cirujanos, o se convierten en interlocutores y vuelven a ver pacientes, a 20 años, su destino es posiblemente el de la desaparición" (D. Luna, comunicación personal, 24 de mayo de 2019).

41. Para más información: https://www.cancerimagingarchive.net/

3.1.5 DPI es una especialidad innovadora

El Dr. Ricardo García Mónaco considera que el DPI ha nacido como una especialidad innovadora, la cual tuvo toda su historia marcada por la implementación de tecnologías que permitieron alcanzar el mayor potencial dentro de su época. “Dentro de la salud, la especialidad el DPI siempre fue pionero en avances tecnológicos. Desde la utilización de los rayos X hasta la creación del resonador magnético. Por otro lado, fue la primera especialidad en implementar masivamente una herramienta como el Sistema de Información Radiológica (RIS por su nombre en inglés *Radiology Information System*) cuando todas las especialidades se mostraban reticentes a cualquier implementación de este tipo. Y así con todos los avances que fueron apareciendo. La IA y ML no serán la excepción” (R. García Mónaco, comunicación personal, 27 de mayo de 2019).

Como ya hemos visto, en el Capítulo 2, el DPI ha tenido una primera incursión en el uso de sistemas informáticos orientados al análisis de imágenes (CAD). Si bien, la precisión de la tecnología no estuvo acorde a la circunstancia, la adopción no fue menor. En 2010, más del 74% de las mamografías en Estados Unidos fueron informadas por médicos que utilizaron algún tipo de CAD como soporte (Oakden-Rayner, 2019).

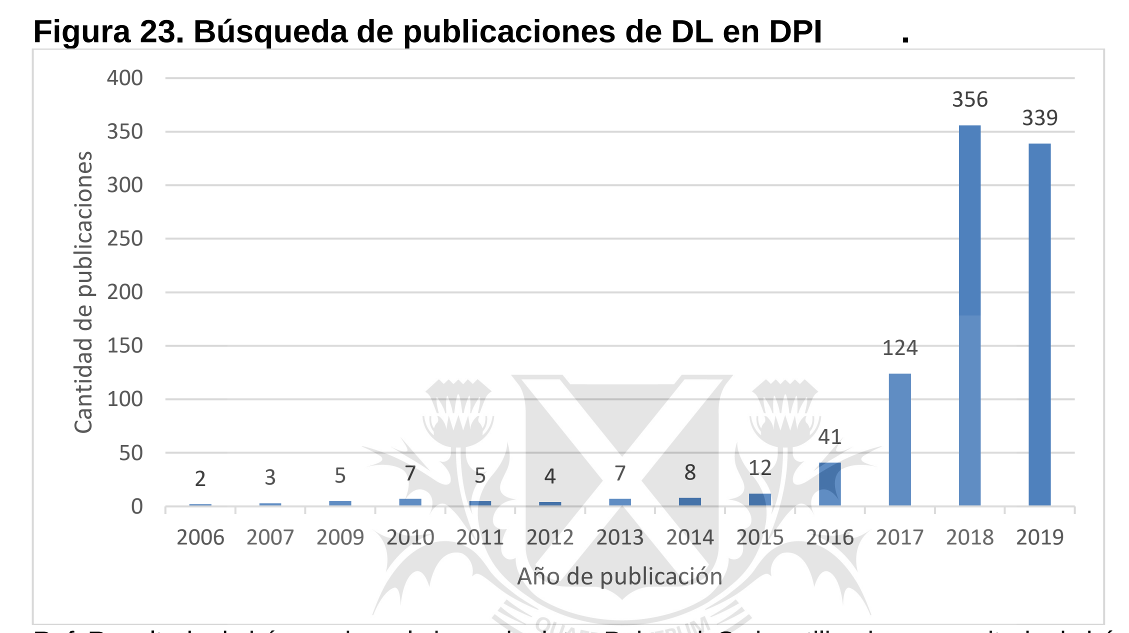
El Dr. Daniel Luna agrega que, dentro del universo de la salud, alineado a la innovación constante que siempre existió en la especialidad, la mayor cantidad de publicaciones de ML y DL que hay actualmente son de DPI (D. Luna comunicación personal, 24 de mayo de 2019).

Asociado a las palabras del Dr. Daniel Luna, hemos realizado una búsqueda de artículos en la base de datos Pubmed[42] con las palabras “Deep Learning AND Radiology”. El resultado de la búsqueda muestra que la investigación ha tenido una

42. Para más información: https://www.ncbi.nlm.nih.gov/pubmed/

explosión entre 2017 y el 2018, habiéndose publicado 124 y 356 artículos respectivamente. Hasta junio de 2019 se han publicado 339 artículos.

Figura 23. Búsqueda de publicaciones de DL en DPI .



Ref: Resultado de búsqueda en la base de datos Pubmed. Se ha utilizado como criterio de búsqueda: "*Deep Learning + Radiology". -* Fuente: Elaboración propia.

3.1.6 Existe la necesidad de generar escalabilidad

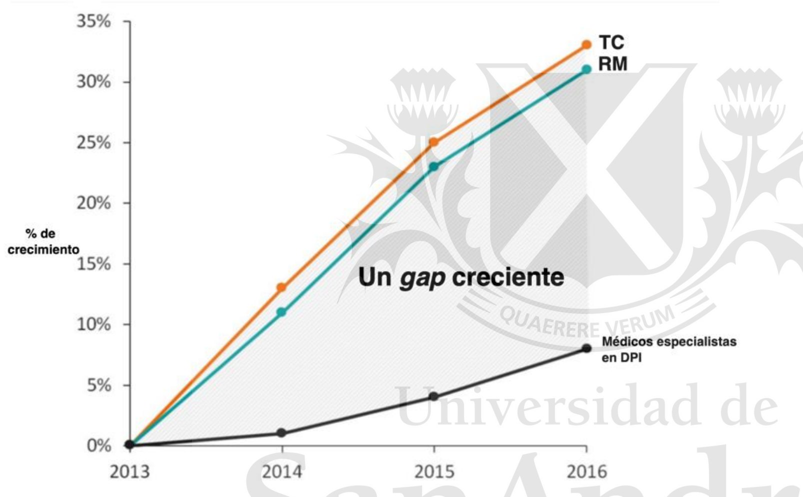
Si bien la cantidad de médicos se está reduciendo a nivel general, este no es el caso del DPI, especialidad que todavía ve en ascenso la cantidad de profesionales habilitados para ejercer en su función (Rosenkrantz et al., 2015). Pero este crecimiento es marginal dado el escenario actual de la salud.

Solamente en 2015 en Estados Unidos, se han realizado 800 millones de exámenes de DPI los cuales generaron aproximadamente 60 billones de imágenes médicas. Estas son cantidades imposibles de procesar, en tiempo y forma, teniendo en cuenta que la cantidad de especialistas en DPI, en Estados Unidos, es de aproximadamente 31.000. Si se quisieran analizar todas las imágenes, cada médico debería ver una imagen cada dos segundos de trabajo, durante todas sus jornadas laborales. Este escenario no es sustentable, lo cual genera una gran oportunidad

para soluciones que tengan como uno de sus focos principales trabajar en la eficiencia y la escalabilidad (IBM, 2016).

En el Reino Unido, entre 2013 y 2016 la cantidad de resonancias y tomografías ha crecido aproximadamente un 30%, mientras que durante los mismos años, la canitdad de especialistas sólo ha crecido aproximadamente un 6% (Board of the Faculty of Clinical Radiology, 2018).

Figura 24. Crecimiento de especialistas en DPI y estudios de resonancia y tomografía.



Ref: Crecimiento de especialistas de DPI (6% entre 2013 y 2017) y estudios de resonancia y tomografía (aproximadamente 30% entre 2013 y 2017) - Fuente: Elaboración propia a partir de (Board of the Faculty of Clinical Radiology, 2018).

El Dr. Diego Slezak considera que los problemas que surgen con el error en la lectura de las imágenes están dados por la cantidad de estudios que deben informar los profesionales. “La Sociedad Inglesa de Radiología, para el caso de las mamografías, aconseja que el profesional que las analiza debe realizar entre 30 y 60 estudios por hora. Es decir, ¡analizar un estudio cada 1 o 2 minutos! Después de una hora de estar realizando eso trabajo, el profesional queda muy cansado. Hay estudios que demuestran que alrededor del 20% de los resultados son erróneos. Y ese error es producido por la sub-lectura, producto de intentar cumplir con los tiempos que el empleador solicita” (D. Slezak, comunicación personal, 28 de mayo de 2019).

Acompañando a las palabras del Dr. Slezak, Berlin (2007) declara que el error entre los estudios de DPI que presentan hallazgos patológicos significativos promedia el 30% (Berlin, 2007).

Las nuevas modalidades de resonancia y tomografía generan mayor información detallada con cortes cada vez más finos. Es decir, cada estudio genera mayor cantidad de imágenes. Teniendo en cuenta que el número de especialistas en DPI no crece de igual forma, la fatiga es un problema. Los modelos de DL pueden ayudar en tareas repetitivas las 24 horas del día (Yasaka & Abe, 2018).

3.1.7 DL está demostrando excelente precisión en los resultados

La posibilidad de procesar imágenes a través de DL ha abierto una oportunidad enorme para mejorar la calidad de los diagnósticos realizados. A continuación, citaremos ejemplos de estudios aplicados distintas regiones del cuerpo: tomografía computada en detección de nódulos en pulmón, resonancia magnética en alzheimer, rayos X para fractura de muñeca y resonancia magnética en realce tardío miocárdico.

3.1.7.1 Tomografía computada de pulmón

Daniel Tse et al. (2019), investigador de Google, ha entrenado un algoritmo de DL para detectar tumores malignos en pulmón. La prueba fue realizada con 42.000 tomografías computadas. El resultado fue, respecto al informe del especialista en DPI, de una disminución del 11% en informes con falsos positivos y una disminución de 5% de falsos negativos.

Alineado a las pruebas de Daniel Tse et al., se ha llevado a cabo en China, una investigación para comprender el impacto de DL en la detección de nódulos pulmonares de diferente tamaño y solidez. Para esto se ha comparado la precisión de dos médicos especialistas en DPI y de DL en tres escenarios distintos: teniendo en cuenta la cantidad de contraste utilizado para el estudio, la edad del paciente y

la marca y modelo del tomógrafo utilizado. En la mayor cantidad de casos, DL ha arrojado mejores resultados que ambos profesionales (Liu et al., 2019). Pero es importante aclarar que en algunos casos puntuales no lo ha logrado.

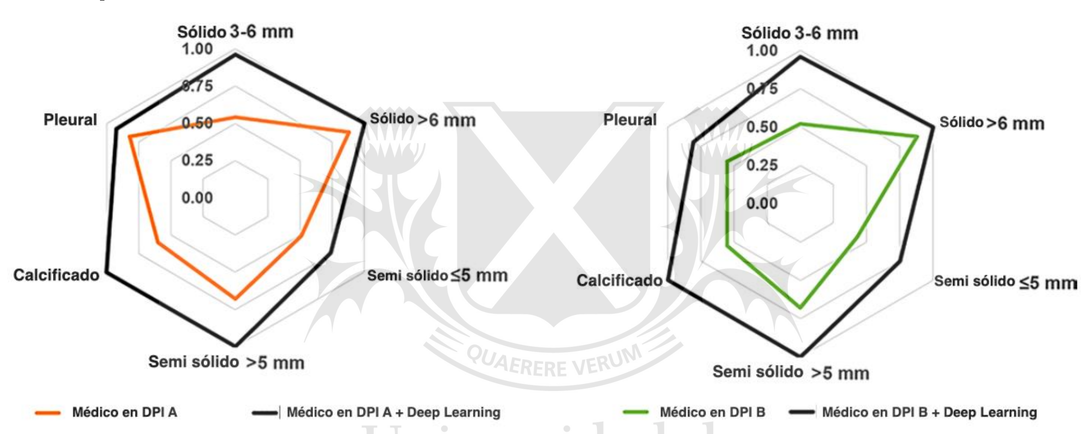
Figura 25. Resultados del análisis con ML de nódulos pulmonares.

Age Group and Nodule Type	Reference Standard	Detected Nodules		
		Deep Learning Model	Radiologist 1	Radiologist 2
Group A				
Solid nodule ≤6 mm	340	218 (64.1)	141 (41.5)	181 (53.2)
Solid nodule >6 mm	30	28 (93.3)	23 (76.7)	23 (76.7)
Subsolid nodule ≤5 mm	24	13 (54.2)	15 (62.5)	18 (75.0)
Subsolid nodule >5 mm	12	11 (91.7)	11 (91.7)	12 (100)
Calcified nodule	15	12 (80.0)	11 (73.3)	12 (80.0)
Pleural nodule	39	33 (84.6)	12 (30.8)	16 (41.0)
Overall true positive	460	315 (68.5)	213 (46.3)	262 (57.0)
False positive*	...	238 (43.0)	...	...
Group B				
Solid nodule <6 mm	1706	1146 (67.2)	645 (37.8)	879 (51.5)
Solid nodule >6 mm	130	114 (87.7)	112 (86.2)	104 (80.0)
Subsolid nodule ≤ 5 mm	650	456 (70.2)	206 (31.7)	355 (54.6)
Subsolid nodule > 5 mm	247	221 (89.5)	166 (67.2)	206 (83.4)
Calcified nodule	154	143 (92.9)	72 (46.8)	89 (57.8)
Pleural nodule	297	241 (81.1)	158 (53.2)	197 (66.3)
Overall true positive	3184	2321 (72.9)	1359 (42.7)	1830 (57.5)
False positive*	...	1921 (45.3)	...	...
Group C				
Solid nodule ≤ 6 mm	1310	855 (65.3)	511 (39.0)	679 (51.8)
Solid nodule > 6 mm	99	86 (86.9)	82 (82.3)	74 (74.7)
Subsolid nodule ≤ 5 mm	510	329 (64.5)	119 (23.3)	304 (59.6)
Subsolid nodule > 5 mm	159	111 (69.8)	60 (37.7)	118 (74.2)
Calcified nodule	142	127 (89.4)	71 (50.0)	78 (54.9)
Pleural nodule	259	190 (73.4)	140 (54.1)	189 (73.0)
Overall true positive	2479	1698 (68.5)	983 (39.7)	1442 (58.2)
False positive*	...	1693 (50.1)	...	...

Ref: Resultados de la prueba realizada para la detección de nódulos pulmonares, según la edad del paciente. Las cifras hacen referencia a la cantidad de nódulos analizados. - Fuente: (Kai Liu et al., 2019).

En el mismo estudio, se han analizado los resultados en la precisión de los especialistas informando sin ningún tipo de soporte, para luego contrastarlo contra los resultados de los mismos profesionales, pero esta vez, utilizando un soporte de ML. En todos de los resultados obtenidos, la precisión de los profesionales ha mejorado. En algunos casos, como se puede ver en la Figura 26, la precisión ha llegado al 100% (Liu et al., 2019).

Figura 26. Resultados de la combinación especialista-ML en la detección de nódulos pulmonares



Ref: Resultados de la prueba realizada para la detección de nódulos pulmonares, comparando la precisión de los médicos especialistas en DPI sin soporte alguno contra los mismos profesionales con soporte de DL. En algunos casos los resultados llegan a tener una precisión del 100% - Fuente: Elaboración propia a partir de (Kai Liu et. al, 2019).

3.1.7.2 Resonancia magnética en Alzheimer

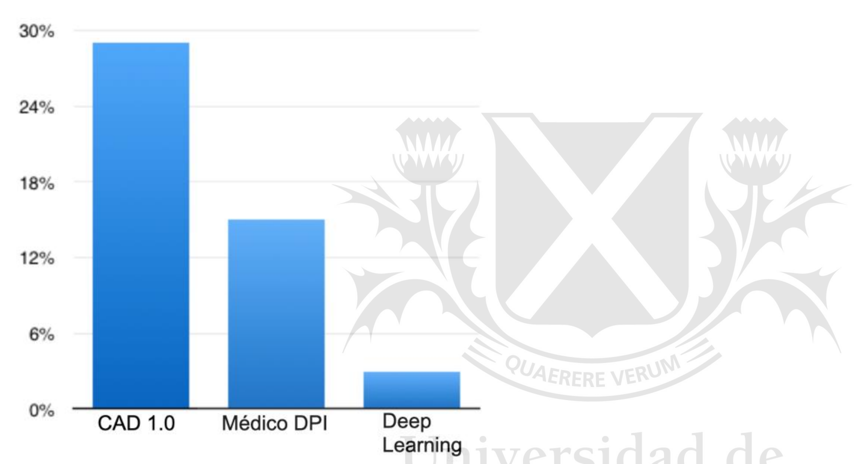
Otro ejemplo, se ha dado con el análisis de resonancias magnéticas con el objetivo de detectar a pacientes con Alzheimer[43]. Esta es una tarea compleja dado que las diferencias en patrones del cerebro e intensidad de la imagen, entre un cerebro con Alzheimer y uno sano, es poca. Los sistemas que se usaban hasta el momento tenían una precisión del 84%. La investigación con técnicas de DL llevó ese número a una tasa de acierto cercana al 99% (Sarraf, DeSouza, Anderson, & Tofighi, 2017).

43. El Alzheimer es un tipo de demencia que causa problemas en la memoria, el pensamiento y el comportamiento. Los síntomas generalmente se desarrollan lentamente y empeoran con el tiempo, hasta que son tan graves que interfieren con las tareas cotidianas (Alzheimer´s Association, 2019).

3.1.7.3 Rayos X en fractura de muñeca

Se han publicado los resultados de la startup Enlitic[44] respecto a las fracturas de extremidades, como ser las de muñeca. Las fracturas analizadas por la fallida primera ola de herramientas CAD mostraron un error de diagnóstico cercano al 30%. Al ser realizado por un especialista en DPI ese número desciende a un 15%. Con DL, el número desciende nuevamente, llegando a error del 3% (J. Wang, 2016).

Figura 27. Precisión en la detección de fractura de extremidades.



Ref: La primera columna muestra el porcentaje de error de una herramientas CAD perteneciente a la primera fallida ola (cercano al 30%). La segunda columna muestra el error en la detección por parte del médico (15%). Por último, la tercera columna muestra el porcentaje de error en la detección por parte de la herramienta basada en DL (3%). Fuente: Elaboración propia a partir de Ark Invest, (J. Wang, 2018).

En la misma línea, Lindsey et al.,(2018) han realizado una investigación sobre la detección de fractura de muñeca. En dicho estudio han demostrado cómo la precisión de los profesionales se ve incrementada con el uso de ML. La evaluación se ha realizado con dos grupos de médicos: uno sin subespecialización en fractura de muñeca y otro subespecializado.

44. Para más información: https://www.enlitic.com/

En el primer grupo, la precisión promedio de los profesionales sin asistencia de ML fue del 80,8%. Por otro lado, el promedio con asistencia de ML fue del 91,5%.

Respecto a la segundo grupo, la precisión promedio de los profesionales sin asistencia fue del 87,5%. Dicho número asciende a 93,9% con asistencia de ML.

3.1.7.4 Resonancia magnética en realce tardío miocárdico

Por último, se ha realizado Japón una investigación con el objetivo de analizar la precisión de DL en resionancias magnéticas para la detección y clasificación de patrones en una afección cardíaca, el realce tardío miocárdico[45]. Para llevar a cabo la prueba se han utilizado tres arquitecturas de RNC: GoogLeNet, AlexNet y ResNet. Las mismas poseen características distintas entre la que se destaca la cantidad de capas, siendo de 22, 8 y 152 capas, respectivamente.

Si bien los resultados promedio del análisis son considerados excelentes (79,5% para GoogLeNet, 78,9% para AlexNet y 82,1% para ResNet) los investigadores concluyen que los mismos son insuficientes para pensarse a la solución independiente del ser humano (Ohta, Yunaga, Kitao, Fukuda, & Ogawa, 2019).

3.1.8 DL permite incrementar la eficiencia de los profesionales

DL permite llegar a una conclusión en una pequeña parte de tiempo respecto a lo que le llevaría al médico interpretarla por sí mismo (Mazurowski et al., 2018).

Uno de los aspectos más prometedores de la utilización de DL en el análisis de imágenes es el ahorro que se puede generar en el tiempo dedicado a cada estudio. En la misma investigación realizada en China por Liu et al., (2019) para analizar el impacto de DL en la detección de nódulos pulmonares, se ha podido observar ahorros de tiempo significativos. Los 15 minutos, promedio, que ha llevado a ambos

45. Identifica regiones con fibrosis miocárdica y permite valorar de forma directa el tejido miocárdico anormal (Dumont et al., 2007).

médicos realizar el informe de cada estudio se han reducido, generando ahorros de entre 5 y 10 minutos.

Por otro lado, la solución de la empresa Arterys[46] provee servicios de interpretación de imágenes y asistencia en el flujo de trabajo, pudiendo reducir el tiempo de 90 minutos a 20 (GE, 2018).

Si bien los argumentos teóricos sugieren que el ahorro de tiempos es un hecho, nuestra investigación no nos ha arribado a una gran cantidad de escenarios donde se hayan demostrado mediciones concretas.

3.2 Aplicaciones de Machine Learning en el Diagnóstico por Imágenes

En el DPI, la interacción entre el especialista y paciente, u otros médicos, es limitada. Esto se debe a que la principal tarea del profesional radica en observar las imágenes de cada uno de los estudios a diagnosticar y generar el informe correspondiente. Esta tarea estructurada y solitaria hacen a este proceso muy atractivo para la aplicación de IA (Mazurowski et al., 2018).

Las aplicaciones más importantes de ML en el proceso de trabajo del especialista en DPI son: detección de enfermedades, diagnóstico y manejo de enfermedades, flujo de trabajo y tareas de interpretación no habituales, alerta de urgencias y capacitación. A continuación, describiremos cada una.

3.2.1 Detección de Enfermedades

El primer hito que deben cumplir las herramientas basadas en ML, al momento de analizar una imagen, es poder discernir entre una normal y otra con una anormalidad. Por ejemplo, en las mamografías, cada imagen contiene miles de

46. Para más información: https://www.arterys.com/

densidades focales individuales, densidades regionales, puntos y líneas geométricas que deben interpretarse para detectar un pequeño grupo de hallazgos sospechosos. En la mayoría de los casos, toda la mamografía debe interpretarse como normal o negativa, lo que agrega mayor complejidad a la tarea de interpretación. El 80% de las mamografías deben leerse como negativas, según la guía ACR BI-RADS[47]. Del 20% restante, muchas serán categorizadas también como benignas. Un algoritmo que detecte, al menos, la mitad de las mamografías como definitivamente benignas reduciría significativamente el esfuerzo del profesional (Mazurowski et al., 2018).

3.2.2 Diagnóstico y manejo de enfermedades

Una vez que se ha detectado una anomalía, continúa el trabajo para determinar un diagnóstico y cómo abordar la enfermedad. Se debe analizar una gran cantidad de características para decidir cómo gestionar el hallazgo. Estas características pueden ser, por ejemplo, tamaño, ubicación, atenuación, bordes, heterogeneidad y cambios en el tiempo. Mientras que para algunos tipos de anomalía la toma de decisiones en relación al diagnóstico y el manejo de la enfermedad sigue pautas directas, para otros tipos de anomalías, los algoritmos de manejo son mucho más complejos.

En la guía BI-RADS, para evaluar lesiones focales en una mama, se clasifica de acuerdo con su forma (oval, redonda o irregular), margen (circunscrito, oculto, microlobulado, indistinto o espiculado) y su densidad (mayor, igual o menor densidad que el tejido glandular, o que contiene grasa). Sobre esas características, el especialista en DPI debe decidir si una mama es probablemente benigna o si requiere seguimiento o biopsia.

47. ACR BI-RADS (*The Breast Imaging Reporting and Data System del American College*) es una guía de clasificación de mamografías según su estadificación.

3.2.3 Tareas de interpretación no habituales

DL puede realizar tareas de interpretación de imágenes que actualmente los médicos no realizan de manera habitual. Un ejemplo es la radiogenómica, la cual tiene como objetivo encontrar relaciones entre las características de imagen de los tumores y sus características genómicas, para así poder ofrecer el mejor tratamiento posible, reduciendo los efectos secundarios del mismo. DL podría facilitar el proceso de incorporar más información disponible de imágenes en la práctica oncológica (Mazurowski et al., 2018).

3.2.4 Capacitación de profesionales

Los modelos entrenados por expertos y especialistas en DPI pueden ser utilizados como herramienta de capacitación para alumnos o médicos en DPI con poca experiencia, con el objetivo de aumentar su conocimiento y confianza en diagnósticos complejos (Yasaka & Abe, 2018).

3.2.5 Alerta de urgencias

DL puede ser utilizado para priorizar y alertar a los especialistas en DPI y médicos en general, cuando un paciente necesita un tratamiento urgente (Yasaka & Abe, 2018).

3.2.6 Asistencia en el análisis y comparación con estudios previos

DL también puede contribuir en facilitar el flujo de trabajo de los especialistas al momento de interpretar las imágenes. Los médicos han visto un crecimiento exponencial en el tamaño y la complejidad de las imágenes a analizar. Para agregar dificultad, las interpretaciones deben realizarse, en gran parte de los casos, en el contexto de una serie de exámenes previos del paciente, los cuales fueron realizados en equipos de diferente tipo, generación y proveedor. Por consiguiente, la identificación de las imágenes adecuadas a observar puede ser una tarea difícil. Una vez que se hayan identificado las imágenes apropiadas, el profesional debe

obtener mediciones precisas y repetidas para garantizar que los valores obtenidos de los exámenes actuales y anteriores puedan compararse (Mazurowski et al., 2018).

3.3 Machine Learning y el impacto en el rol del médico especialista en DPI

Susskind & Susskind (2016), ambos abogados de la Universidad de Oxford, vaticinaron que la tecnología reemplazará a gran parte de los médicos, al igual que a otros profesionales. El argumento utilizado es que cuando las tareas realizadas pueden ser descompuestas en partes, se evidencia que gran parte son rutinarias y basadas en procesos. Es decir, no requieren creatividad, empatía o juicio alguno.

Dado que una parte importante del trabajo del médico especialista es analizar las imágenes y detectar presencia de irregularidades, Geoffrey Hinton, pionero en RN, declaró en una conferencia que se debe dejar de entrenar a los médicos en diagnóstico por imágenes[48]. El motivo es que la IA, próximamente, será mejor calificada que un humano para detectar irregularidades (Langlotz, 2019).

El Dr. Facundo Manes opina al respecto: “El tomógrafo en su momento fue una amenaza para los semiólogos ya que veían que la tomografía podía quitarles parte de su campo de acción. Y, de hecho, lo hizo. Hace décadas, los síntomas semiológicos eran clave. Actualmente, alguien que solicita una tomografía puede observar con mayor claridad qué pasa en el organismo. Sin embargo, esto no erradicó la medicina ni extinguió a los médicos. Los médicos se tuvieron que readaptar. Y eso veo que va a suceder con la IA en la salud. Veo que va a ser una herramienta muy útil para que los médicos tengamos más datos. Pero los que tomen las decisiones van a ser los médicos. Si bien debemos adaptarnos a la nueva realidad, que está empezando, lo veo como una nueva tecnología que va a venir a

48. Para más información: https://www.youtube.com/watch?v=2HMPRXstSvQ

aportar en la interfaz máquina - humano" (F. Manes, comunicación personal, 29 de mayo de 2019).

El Dr. Daniel Luna considera que más allá de los avances que pueda haber en las tecnologías, hay una cuestión cultural que hace que la presencia del médico siga siendo necesaria. "Históricamente, los pacientes se entregaron a una persona, ya sea un gurú, un chamán, un sacerdote o un médico. Es una instancia social que tiene más de 4.000 años. No es tan simple. Los ingenieros intentan reducirlo a una sistematización. Aquí hay distancias culturales y sociales, no tecnológicas. La sociedad no está preparada para pensar su salud en términos de IA. Y menos de IA como una entidad autónoma. Si una persona se tiene que realizar un estudio, por ejemplo, de un cáncer de pulmón o un cáncer de mama, va a querer ir al mejor médico por la presencia misma del médico. No por la herramienta que tenga por detrás" (D. Luna comunicación personal, 24 de mayo de 2019).

En la misma línea se encuentra el Dr. Ricardo García Mónaco quién considera que el paciente necesita el soporte del profesional. Pero también reconoce que esa necesidad puede variar según la región del mundo. "Los pacientes, al menos de las generaciones actuales, requieren de la interacción con los médicos. Necesitan la contención. Sobre todo, cuando los resultados de los exámenes atentan contra la salud. Si bien puede haber cambios en la relación médico-paciente, esto hay que analizarlo en cada región. No es lo mismo lo que se espera en Japón sobre la contención de un profesional que lo que se espera en los países de América Latina" (R. García Mónaco, comunicación personal, 27 de mayo de 2019).

El Dr. Diego Slezak considera que no sólo el rol del especialista en DPI no desaparecerá, sino que se enriquecerá. "El especialista en DPI no va a desaparecer. Se los va a necesitar aún más que antes. Por ejemplo, para mejorar las técnicas de los algoritmos. En nuestra empresa, Entelai, un tercio del equipo está compuesto por médicos especialistas en DPI. La IA les está dando más trabajo que antes. Anotan imágenes, revisan que los algoritmos funcionan. ´Fijate que tu red está sub

calculando la corteza temporal´. Este tipo de cuestiones médicas son evidenciadas por un médico especialista, no por un ingeniero. Los especialistas en DPI que se entreguen al uso de IA serán los ganadores. Es posible que, si de realizar mediciones se trata, haya una pérdida de terreno respecto a la IA. Pero no en el trabajo de interpretación general. Incluso para los especialistas que basan la mayor parte de su tiempo en informar, estos no van a ser reemplazados. Van a poder informar mejor" (D. Slezak, comunicación personal, 28 de mayo de 2019).

Por otro lado, también diferenciándose de la opinión de Hinton, en el libro *Prediction Machines* (Agrawal Ajay, Gans, & Goldfar, 2018) los autores afirman que el trabajo de especialista en DPI seguirá existiendo, pero con varias modificaciones. El tiempo que emplearán leyendo imágenes se reducirá para ocupar mayor tiempo en otros cinco roles.

El primer rol está basado en que el especialista deberá determinar exactamente qué estudios se deben realizar para cada paciente. El segundo rol está centrado en que existen dos tipos de especialistas, los que están enfocados a la obtención de imágenes y los que están enfocados a la intervención. Sobre estos últimos, el trabajo no se vería afectado significativamente. El tercer rol está basado en que los especialistas en DPI son los "médicos de los médicos". Es decir, muchas veces son aquellos que comunican el resultado de las imágenes a los médicos de otras especialidades para ayudar a seleccionar el mejor tratamiento. Si bien en el futuro la IA determinará la probabilidad de mejor tratamiento, en el corto y mediano plazo los especialistas seguirán teniendo esta responsabilidad. El cuarto rol está centrado en la capacidad que deben tener los médicos especialistas en DPI para entrenar a las mismas máquinas que procesarán las imágenes. El quinto rol está basado en que los profesionales seguirán conservando la decisión final acerca de su realizar un procedimiento invasivo. El médico puede tener información que la máquina no, como puede ser el estado de salud general, el nivel de estrés ante un falso negativo, o cualquier otro dato de consideración. Toda esta información que posee el médico

Universidad de SanAndrés

puede hacer cambiar la recomendación de una máquina basada en IA que sugiera realizar el procedimiento invasivo.

Por último, el Dr. Bertalán Mesko, director del sitio web *The Medical Futurist*[49], es autor de una frase que media entre la opinión de Hinton y el resto de los autores. La misma hace referencia a que la IA no reemplazará a los médicos, sin embargo, los médicos que utilicen IA reemplazarán a los que no lo hagan.

3.4 Ética y regulación de Machine Learning en Diagnóstico por Imágenes

3.4.1 Anonimización de las imágenes

La Dra. Margaret Chan, ex Directora General de la OMS, advierte que la IA es una nueva frontera para el sector de la salud y que su potencial en la atención sanitaria es enorme, pero también lo es la necesidad de tomar algunas precauciones" (Kos, 2018).

Una encuesta en el Reino Unido reveló que el 63% de la población adulta no se siente cómoda con la utilización de sus datos personales para mejorar el sistema de salud. Por otro lado, también posee una opinión desfavorable acerca de la idea de que sistemas basados en IA reemplacen a médicos y enfermeras en las tareas que generalmente realizan (Vayena, Blasimme, & Cohen, 2018).

El acceso a un repositorio de información sensible, como es la información del paciente, es necesario para poder crear valor a través de la IA. Garantizar la protección de la intimidad del paciente, como de sus datos, es de suma importancia.

Actualmente, el uso de IA plantea dos problemas relacionados con los datos recopilados para el entrenamiento de los sistemas de DPI. Por un lado, los datos deben estar protegidos de las mismas entidades que los recopilan. Por otro lado,

49. Para más información: https://www.youtube.com/watch?v=a1QguDFMBM8

los mismos datos están amenazados por ataques cibernéticos, tanto a las entidades que los recopilan como así también a las soluciones de IA que harán uso de ellos (Pesapane, Volonté, Codari, & Sardanelli, 2018).

Para dar soporte a esto, la *HIPAA* ha desarrollado métodos para la eliminación de información sensible de los registros médicos[50]. Según W. Nicholson Price, profesor asistente de la Facultad de Derecho de la Universidad de Michigan y miembro del cuerpo docente del Centro Petrie-Flom de Políticas de Derecho de la Salud, Biotecnología y Bioética de la Facultad de Derecho de Harvard, una vez que se genera este protocolo de eliminación de información sensible, no hay recursos legales disponibles para limitar el uso de los datos. Por otro lado, si hubiera que depender únicamente de los pacientes que voluntariamente desean compartir sus datos, se incurrirá automáticamente en sesgos que atentan contra el avance de la tecnología (Forbes, 2019a).

En relación a este tema, el Dr. Diego Slezak considera que la eliminación de la información sensible de las imágenes no garantiza, de ninguna manera, que no se pueda conocer a quién pertenece una imagen. “Que existan procesos para eliminar cualquier información que haga referencia a un paciente no garantiza la seguridad del mismo. Todo hace pensar que la imagen de alguna región del cuerpo pueda corresponder unívocamente a una persona. Por lo tanto, la imagen entera en sí misma se transforma en información sensible” (D. Slezak, comunicación personal, 28 de mayo de 2019).

Por su parte, el Dr. Federico Milano, aclara que, si bien los estudios del paciente deben estar anonimizados, algo que debe ser pedido por el comité de ética del establecimiento de salud donde se han generado las imágenes, el paciente debe

50. Es una norma establecida por la HIPAA, en Estados Unidos, para comprender y controlar cómo se utiliza la información relacionada a la salud de las personas. Para más información: https://www.hhs.gov/hipaa/for-professionals/security/guidance/index.html

dar su consentimiento informado[51] firmado que permita el uso de sus estudios para investigación. Tiene que expresar su consentimiento porque la imagen es propiedad del paciente" (F. Milano, comunicación personal, 6 de junio de 2019).

3.4.2 El dilema de la Caja Negra

Existe otro problema que es el de las, comúnmente conocidas, Cajas Negras. En las RN, generalmente utilizadas en soluciones para el área de DPI, es muy difícil comprender qué han aprendido verdaderamente y cómo están tomando cada una de sus decisiones. Únicamente conocemos la información de entrada al algoritmo y su salida. Pero no es posible conocer el mecanismo a través del cual se llegó a una decisión específica. En otras industrias, posibles errores pueden ocasionar pérdidas económicas gigantescas. Pero en la salud esto puede se puede transformar directamente en la pérdida de vidas. Una encuesta realizada a líderes de empresas de salud en Estados Unidos reveló que el 50% de ellos considera que se producirán errores fatales, no funcionará correctamente y no cumplirá con las expectativas que hay actualmente (Vayena et al., 2018).

Los algoritmos de ML basados en RN se verán expuestos ante los desafíos que plantean las entidades regulatorias. La GDPR[52], es la entidad que se encuentra en vigencia desde 2018 en Europa. Para que las compañías puedan hacer uso de datos generados en la Unión Europea, o incluso puedan operar en dicho territorio, se las alienta a utilizar técnicas de ML que permitan interpretar la decisión tomada, de manera tal que se pueda demostrar que el modelo predictivo no genera discriminación contra determinados sectores de la sociedad. Este concepto es denominado "derecho a una explicación", el cual dependiendo de la interpretación que se le haga a las regulaciones definidas para la Unión Europea, puede plantear

51. El consentimiento informado para actos médicos e investigaciones de salud es el proceso a través del cual el paciente expresa su voluntad, basada en información clara, precisa y adecuada, acerca de, entre algunos puntos destacados, procedimiento propuesto, beneficios esperados y riesgos.

52. EU General Data Protection Regulation (GDPR) es el ente que regula la protección de los datos en Europa. Para más información: https://ec.europa.eu/commission/priorities/justice-and-fundamental-rights/data-protection/2018-reform-eu-data-protection-rules_en

un gran desafío a futuro para las empresas que, por las características de su negocio, no pueden dejar de utilizar RN (Kaminski, 2018). Este problema también es central para empresas como Google. Su CEO, Sundar Pichai, considera que no es suficiente con conocer que un modelo de IA funciona, se debe saber conocer también cómo lo hace (Shankland, 2019).

Alineado a esto, existen investigaciones que tienen por objetivo la explicación de cómo hace un algoritmo de ML para arribar a un resultado específico. *Explainable Artificial Intelligence* (XAI) es un programa de DARPA[53] el cual tiene por objetivo producir modelos explicables manteniendo el alto nivel de performance en la predicción, permitiendo a los usuarios entender, confiar y administrar los sistemas de IA (Gunning, 2018).

Para el Dr. Diego Slezak el dilema de la Caja Negra no es tal y considera que el problema a resolver es regulatorio y que la FDA estará alineada a esta visión. "¿Para qué se quiere conocer lo que hace DL a través de sus algoritmos? Si podés saber cuán bien funciona y en qué casos. Es solo cuestión de analizar las regulaciones de la FDA cuando determinan la aprobación de una nueva droga, Lo que importa en la nueva droga es si mata al ser humano o no mata el ser humano, si cura o no cura la enfermedad. Para eso se ejecuta un protocolo, segmentado en distintas fases y regular la droga en los distintos escenarios. Le están pidiendo a DL lo que no le piden al ser humano y a los laboratorios en el desarrollo de nuevas drogas. De hecho, la FDA lo tiene resuelto. Para aprobar un producto basado en ML para salud, hay que presentar un protocolo como si fuera una droga: quiénes son tus pacientes, de dónde los vas a obtener, qué *dataset* vas a utilizar, cuántos pacientes vas a utilizar como muestra y qué pruebas estadísticas vas a observar. Antes de hacer cualquier prueba se tiene que validar todo. Luego, de forma ciega, vas a tener que ejecutar tu prueba con DL. Si el resultado es el esperado, estás aprobado. Caso

53. *Defense Advanced Research Projects Agency* (DARPA) es una agencia del Departamento de Defensa de Estados Unidos responsable por el desarrollo de tecnologías emergentes para su uso militar.

contrario, estás reprobado. ¿Acaso realmente importa entender a tu RN? Es verdad que los sesgos son un problema. Entonces hay que aplicar normativas internacionales. Por ejemplo, que no puedas aplicar algoritmos aprobados en Estados Unidos, por internet, a pacientes que no viven en Estados Unidos. El problema es regulatorio. Yo creo que nunca se van a entender las redes que estamos desarrollando hoy. Son muy complejas, grandes y profundas. Difícilmente vayamos a poder traducirlas en modelos matemáticos elegantes que expliquen cómo funcionan. Igualmente, considero que está muy bien que se estudie el cómo. Sobre todo porque al decodificarlas tendremos más posibilidades de optimizarlas. Es decir, llegar a los mismos resultados con redes menos complejas" (D. Slezak, comunicación personal, 28 de mayo de 2019).

En relación a los sesgos mencionados, MIT lanzó un modelo de DL que promete predecir el cáncer de mama, hasta 5 años antes de su aparición. Otro de los objetivos de dicho proyecto es que la evaluación del riesgo de contraer la enfermedad sea más preciso para minorías raciales. Esto es necesario ya que modelos previos fueron desarrollados con imágenes asociadas a población blanca, lo que hacía al modelo menos preciso para otras razas. El modelo en cuestión es igual de preciso para mujeres de raza blanca como de raza negra. Y esto es realmente importante, dado que las mujeres de raza negra tienen un 42% más de probabilidades de morir por cáncer de mama. El motivo de esta diferencia se da por una amplia cantidad de factores, que incluyen diferencias genéticas a tomar en cuenta para la detección y, por otro lado, acceso al sistema de salud (Adam Conner-Simons, 2019).

A diferencia de lo dicho por el Dr. Diego Slezak, el Dr. Tomás Crivelli considera que es importante conocer el cómo del algoritmo. Aunque también cree que el problema de la Caja Negra es algo sobre lo que se posee cada vez más información. Incluso confía en los avances que ya existen en la materia. "Son cada vez menos una Caja Negra, se sabe mucho ahora de cómo actúan y que aprenden las capas intermedias de la RN. Sin embargo, puede ser una Caja Negra para quien las entrena, por la

facilidad de entrenamiento *end-to-end*, es decir, que no se necesita hacer ingeniería del problema para encontrar la solución. El riesgo y la limitación está dado siempre por el conocimiento del problema que se tiene. En mi opinión, siempre hay que comprender el proceso que se modeliza para explotar al máximo la herramienta. Es muy importante comprender, para un problema en particular, qué es lo que aprende la red en sus distintas capas. El trabajo de muchos investigadores se ha basado en cómo descomponer y visualizar esta información. Sin duda es clave para entender cómo una red "razona" internamente para llegar a una conclusión. Algunos resultados han mostrado que incluso lo que las RN “ven” en las imágenes para clasificar, no es lo mismo que los que ven los médicos. Por otro lado, en términos prácticos, analizar lo que sucede en el interior de las redes permite optimizar recursos, entender qué partes del entramado de neuronas aporta más a la solución de un determinado problema y, en consecuencia, refactorizar y comprimir modelos” (T. Crivelli, comunicación personal, 13 de junio de 2019).

El Dr. Daniel Luna comparte la visión que posee el Dr. Diego Slezak acerca de que no es fundamental conocer cómo resuelve el algoritmo, sino que resuelva en forma correcta. “Respecto al dilema de la Caja Negra, la FDA en Estados Unidos solo pedirá que los resultados obtenidos sean correctos y reproducibles. Si esto se logra, a quién le importa lo que se hizo dentro de esa Caja Negra” (D. Luna comunicación personal, 24 de mayo de 2019).

El Ing. Hernán Borré considera que si bien, se está realizando un trabajo de investigación importante sobre la decodificación de la Caja Negra, todavía los estudios se encuentran en una etapa inicial. Por otra parte, considera que, si bien es necesario avanzar en esta línea para poder justificar la toma de decisiones, se le está solicitando más explicaciones a la máquina de la que pedimos actualmente el ser humano. “Respecto a la Caja Negra, hay mucha gente trabajando en esto. Es lo que se conoce como *interpretability*. Por ahora se encuentra en una etapa inicial. Si bien es verdad que las empresas van a tener que poder justificar sus acciones tomadas, pareciera un poco injusto para las máquinas ya que a los seres humanos

no se nos pregunta por cada paso a través del cual llegamos a una decisión" (H. Borré, comunicación personal, 14 de mayo de 2019).

El Dr. Federico Milano considera que resolver el dilema de la Caja Negra es una necesidad, incluso por la seguridad de la misma empresa tecnológica. Para explicar esto hace un paralelismo con la aprobación de drogas llevada a cabo por los grandes laboratorios. "Hay una diferencia fundamental con la aprobación de una droga por parte de un gran laboratorio. Si se encuentra que la droga ha causado algún tipo de daño, y esto se demuestra, la FDA ordena un *recall*, a través del cual la misma salga de circulación. Si tuvieras que retirar, por un *recall*, un sistema del mercado, e ingresar nuevamente en un proceso de aprobación, es muy probable que haga desaparecer la empresa" (F. Milano, comunicación personal, 6 de junio de 2019).

3.4.3 Niveles de Regulación

Por su parte, la FDA categoriza los proyectos de salud a aprobar en tres clases (Clase I, Clase II y Clase III), de acuerdo a sus usos y riesgos. A mayor riesgo, más estricto el control (Pesapane et al., 2018). La Comisión Europea (en adelante, CE) hace lo mismo, a través de la EU MDR[54] con la salvedad de que divide la clase II en dos subcategoría, Clase II A y Clase II B (Harris, 2019).

Las Clases pueden categorizarse de la siguiente forma:

- ***Clase I.*** Riesgo bajo. Como, por ejemplo, estetoscopios o termómetros.
- ***Clase II A y II B.*** Riesgo medio. Como, por ejemplo, lentes de contacto.
- ***Clase III.*** Riesgo alto. Como, por ejemplo, instrumental quirúrgico o un desfibrilador implantado.

54. *EU Medical Device Regulation* (MDR) hace referencia a la regulación Europea sobre los disposivos médicos.

Generalmente las soluciones basadas en ML son catalogadas como Clase II A o Clase II B, dependiendo del uso que se le vaya a dar al algoritmo. Podría ser Clase III también, si así lo definiera el ente regulador (Harris, 2017).

Figura 28. Niveles de regulación de la FDA y de la EU MDR.



Ref: Niveles de aprobación utilizados por la FDA y la CE. Esta última realiza una división en el Nivel II (Nivel II A y Nivel II B). A mayor complejidad de la solución y riesgo para el paciente, mayor es el Nivel que le corresponde - Fuente: Elaboración propia a partir de *How to get clinical AI tech approved by regulators* (Harvey, 2017).

Por este motivo, la aprobación de los entes regulatorios de un sistema de IA que no necesita supervisión del especialista en DPI es más compleja y, en términos legales, son desarrollados y presentados como herramientas de asistencia a los profesionales y no como sustitutos (Pesapane et al., 2018).

A pesar de las palabras de Pesapane (2018), la FDA, en 2018, ha aprobado para su comercialización el primer dispositivo oftalmológico autónomo. El mismo realiza una evaluación sin la necesidad de que un médico oftalmólogo interprete las imágenes o los resultados. El nombre del producto es IDx-Dr[55], perteneciente a la

55. Para más información: https://www.eyediagnosis.co/

empresa IDx. El mismo es utilizado para detectar retinopatía diabética en imágenes de retina.

Si bien la FDA ha aprobado muchas soluciones con supervisión de un humano y una única sin supervisión (IDx-DR), todas estas fueron aprobadas para su uso comercial apoyadas en un algoritmo "cerrado" [56]. La FDA pareciera comprender que esto es una limitación para los sistemas basados en ML, dado que parte de su valor está dado en cómo, a través de la experiencia, puede ir evolucionando para lograr resultados cada vez más precisos. Su naturaleza iterativa, autónoma y adaptativa, hace que sea una verdadera necesidad una nueva regulación que facilite el ciclo de aprobación para la mejora del producto. Es por esto, que en 2019, lanza un artículo de discusión "*Proposed Regulatory Framework for Modifications to Artificial Intelligence/Machine Learning* (*AI/ML) - Based software as a Medical Device (SAMD*)" planteando este problema y la necesidad de un cambio en la regulación actual para dichas soluciones (FDA, 2019).

3.4.4 Responsabilidad legal

¿Quién será demandado o acusado en caso de que un sistema de DPI basado en ML cometa un error?

Los sistemas basados en ML están diseñados para aprender a través de sus experiencias, las cuales son obtenidas a través del entrenamiento que se realiza con estudios previos. Dado el análisis de un estudio, un especialista en DPI tomaría una decisión en base a una cantidad de posibilidades entendidas como más probables. Distinto es el caso de los sistemas basados en ML, los cuales toman en su análisis todas las posibilidades existentes, resultando imprescindibles para los humanos, impredecibles. Mientras ML sean utilizadas como un soporte al especialista en DPI en su toma de decisión, no parece tener mucho sentido

56. Un algoritmo "cerrado" es aquel que genera el mismo resultado cada vez que es utilizada la misma entrada y no cambia con su uso (FDA, 2019).

considerar al desarrollador del sistema negligente por no haber previsto algo considerado como imprevisible. Es por esto que tanto la responsabilidad ética como legal en la toma de decisiones permanecerán en el profesional y en el prestador de salud. La información provista por ML debe ser relevante y tenida en cuenta, pero de ninguna manera concluyente (Pesapane et al., 2018).

En el caso de IDx, el mismo CEO de la empresa, Michael Abramoff, aclaró en un panel realizado en 2018 en la *Federal Trade Comission*[57] de Estados Unidos que, para las soluciones autónomas de IA, la empresa proveedora del servicio es quien asume la responsabilidad de los resultados obtenidos. De la misma forma que un médico, IDx posee un seguro de mala praxis por su producto IDx-DR, para el caso de que exista, en algún momento, un problema de responsabilidad (Abramoff, 2018).

Sin embargo, al ser una solución reciente, todavía no contamos con alguna denuncia de mala praxis para analizar cómo actuó el seguro o cómo resolvió la justicia.

3.5 Problemática del los datasets

Si bien la cantidad de imágenes abunda, el Dr. Tomás Crivelli, considera que contar con las muestras de datos representativas, suficientes y su clasificación, es tal vez los mayores problemas que poseen los proyectos de ML y DPI. “El problema principal de muchas aplicaciones de DL, y especialmente en el caso de DPI, es disponer de datos, en cantidad y de calidad. Cuando uno habla de recolectar datos y etiquetarlos, puede resultar relativamente fácil hacerlo para imágenes del mundo que nos rodea. Pero en el caso de la salud, hay dos problemas. El primero es que el etiquetado es muy costoso, ya que lo debe realizar un médico especialista. En segundo lugar, los datos en sí pueden llegar a ser escasos, además de privados y

57. *Federal Trade Comission* (FTC) es una agencia independiente del gobierno de los Estados Unidos cuya misión principal es la defensa del consumidor y la eliminación y prevención de prácticas anticompetitivas.

delicados. Resolver estos problemas es fundamental. Parte de este problema se resuelve implementando una filosofía adecuada de datos, dentro de los centros de diagnóstico, que permitan almacenar la información organizada y estructurada. Los prestadores de salud deben comprender el valor de la información almacenada" (T. Crivelli, comunicación personal, 13 de junio de 2019).

Lugo-Fagundo, Vogelstein, Yuille, & Fishman (2018) coinciden con la visión del Dr. Tomás Crivelli, haciendo referencia a que, si bien contar con las imágenes es fundamental, uno de los grandes problemas es su preparación para poder ser utilizadas para entrenar a los algoritmos de DL. Los sueldos de los profesionales involucrados y el entrenamiento son algunos de los costos más importantes a tener en cuenta. Para sortear esta etapa, en forma exitosa, se requiere una gran cantidad de tiempo, recursos, experiencia y trabajo.

Por estos motivos, el Dr. Gustavo Pantol se encuentra, actualmente, realizando informes de Resonancias Magnéticas para una empresa en Estados Unidos. La misma solicita, a los especialistas en DPI, rotular los estudios analizados de manera tal que su uso sea posible para bajar los costos y facilitar futuros entrenamientos de algoritmos (G. Pantol, comunicación personal, 12 de junio de 2019).

Si bien el etiquetado es muy costoso, no todos los escenarios requerirían una abundante cantidad de imágenes dado las características de las imágenes médicas. "Si tengo que entregar una red para segmentar tejido cerebral, tal vez con 10 resonancias sea suficiente. Es decir, con pocos datos. Esto es posible ya que las imágenes médicas se caracterizan por su regularidad. Esta es una de las ventajas" (E Ferrante, comunicación personal, 1 de Julio de 2019).

3.5.1 Métodos para reducir el costo de entrenamiento

Existen un método para intentar reducir el costo, tanto de la creación de la red neuronal como del entrenamiento. Su nombre es "*Transfer Learning".* A través de esta técnica se transfiere el conocimiento adquirido por una RN en un dataset a otro

dataset, compuesto por información completamente diferente. En el caso de imágenes médicas, este método significa, entrenar el algoritmo con imágenes no necesariamente médicas. Las RN entrenadas de esta manera pueden comportarse tan bien como si hubieran sido entrenadas en forma convencional (McBee et al., 2018).

Otro método para reducir el costo, ya sea por falta de imágenes o de recursos para generar el etiquetado, es la técnica conocida como "*data augmentation"*. A través de la misma se puede agrandar el tamaño del *dataset.* Esto se realiza aplicando transformaciones aleatorias a las imágenes, siempre mateniendo la lógica con el etiquedo ya hecho. Ejemplos de transformaciones que pueden ser realizadas son: rotar, agrandar y deformar. De esta forma se logra aumentar el tamaño del dataset de entrenamiento (Chartrand et al., 2017).

El Dr. Enzo Ferrante considera que la técnica de *data augumentation* puede ser útil pero su alcance es limitado. "…es útil pero no suple la variabilidad real de los datos. Su alcance es limitado. Permite realizar cambios simples, como estirar la imagen, rotarla. Pero tiene un limite. Te pueden dar un 10% más de precisión. Pero nunca van a ser que un problema que no podías resolver lo vayas a poder resolver perfecto" (E Ferrante, comunicación personal, 1 de Julio de 2019).

3.6 Impacto en el flujo de trabajo del profesional

Los resultados de las soluciones utlizadas deben estar integradas completamente al flujo de trabajo de los médicos y presentadas al momento de la primera lectura. Las empresas desarrolladoras del software deben hacer acuerdos con los proveedores de las modalidades para asegurarse que las soluciones se encuentren muy bien integradas (Harris, 2018c).

Los médicos pueden estar dispuestos a aceptar el uso de una aplicación más. Pero no es realista esperar que utilicen múltples aplicaciones. Cada vez que el médico

sale de su plataforma principal para abrir la solución de IA, se pierde tiempo. Esto será dificil de justificar para las plataformas con una oferta limitada de algoritmos. Además, el esfuerzo de integración asociado a cada solución de IA será prohibitivo (Harris, 2018a).

Asociado a esto, el Dr. Tomás Crivelli considera que la integración con los flujos de trabajo puede ser más importante que una mayor precisión del algoritmo. “Finalmente, como en toda aplicación real, el uso de ML tiene que estar guiado por el caso de uso y la utilidad, más que por la precisión. Sin embargo, este aspecto muchas veces se desprecia. Sobre todo, por la velocidad en que los avances científicos, todavía inmaduros, están llegando a manos de las empresas. Por ejemplo, puede ser mucho más útil un algoritmo con performance de 80% integrado en un *workflow* de diagnóstico eficiente, que un algoritmo de precisión 95%, que no se adapte bien al uso” (T. Crivelli, comunicación personal, 13 de junio de 2019).

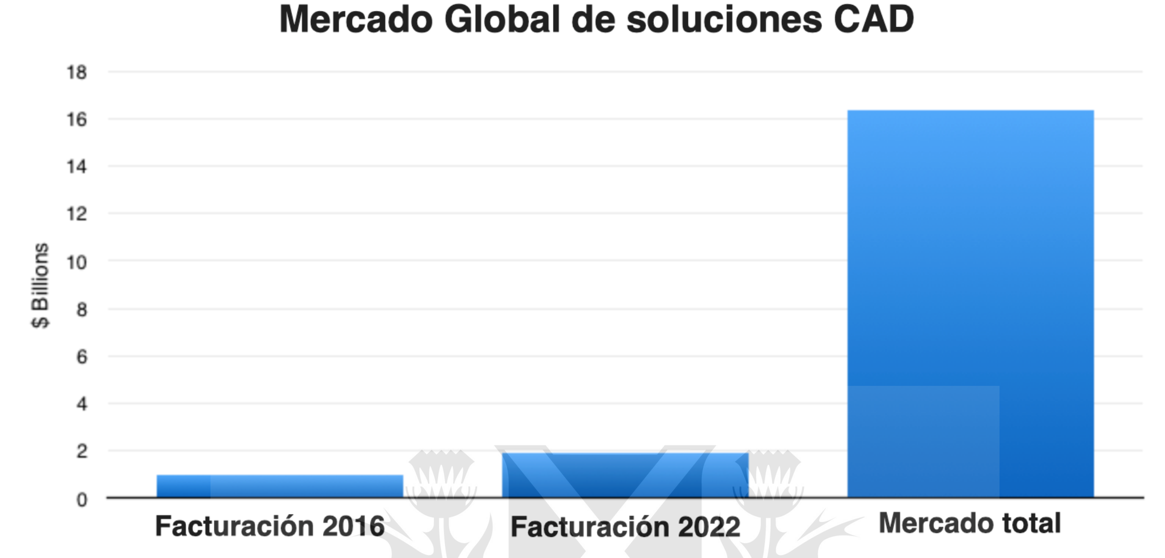
Alineado a esta posición, se encuentra la del Dr. Federico Milano. “La precisión de los algoritmos no va a garantizar la compra del producto ni el uso de los médicos. Es fundamental que las soluciones se integren a los *workflows* ya existentes" (F. Milano, comunicación personal, 6 de junio de 2019).

3.7 Mercado de Machine Learning en Diagnóstico por Imágenes

3.7.1 Tamaño de mercado

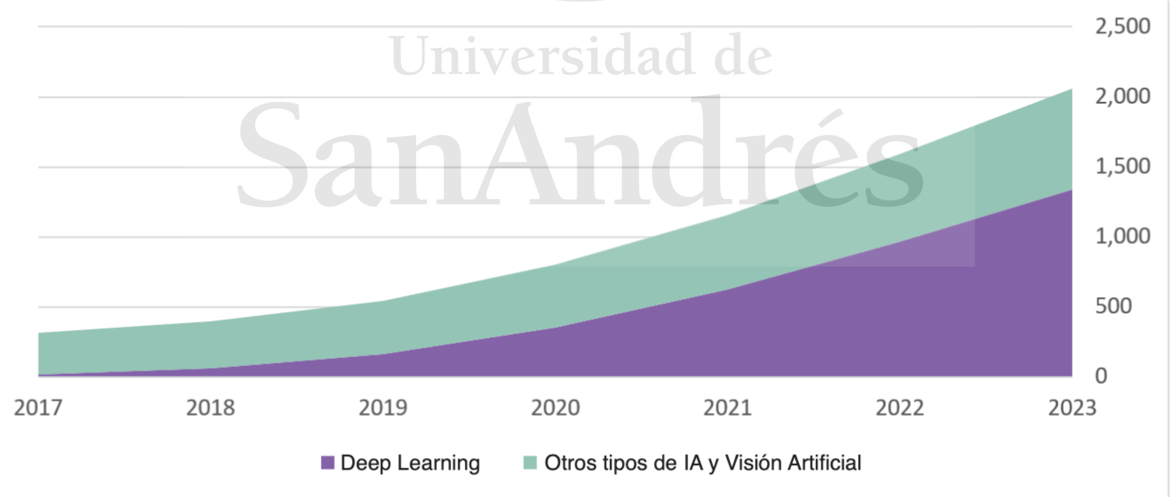
La posibilidad de llegar a diagnósticos más rápidos, económicos y precisos es entendida por las empresas como una gran oportunidad. El mercado global de CAD estimado es de $2 billones de dólares para el 2022. Por otro lado, se estima que el mercado potencial total posee un valor de $16 billones de dólares (J. Wang, 2016). En consonancia, Harris (2018a) también estima, como se muestra en la Figura 30, un mercado de $2 billones de dólares para 2023.

Figura 29. Tamaño estimado de mercado para herramientas de asistencia a la detección y diagnóstico.



Ref: Estimación de tamaño de mercado global potencial para herramientas basadas en ML para la asistencia en el DPI. - Fuente: Elaboración propia a partir de (Wang, 2018).

Figura 30. Valuación estimada del mercado de ML, Visión y otras técnias de IA para el DPI.



Ref: Valuación estimada del mercado de ML, Visión y otras técnicas de IA, orientadas al DPI - Fuente: Elaboración propia a partir de (Harris, 2018a).

3.7.2 Acuerdos entre los actores del mercado

En Estados Unidos, los grandes jugadores más tradicionales en el sector salud (entre los que se destacan GE, Philips, Siemens) como así también los nuevos

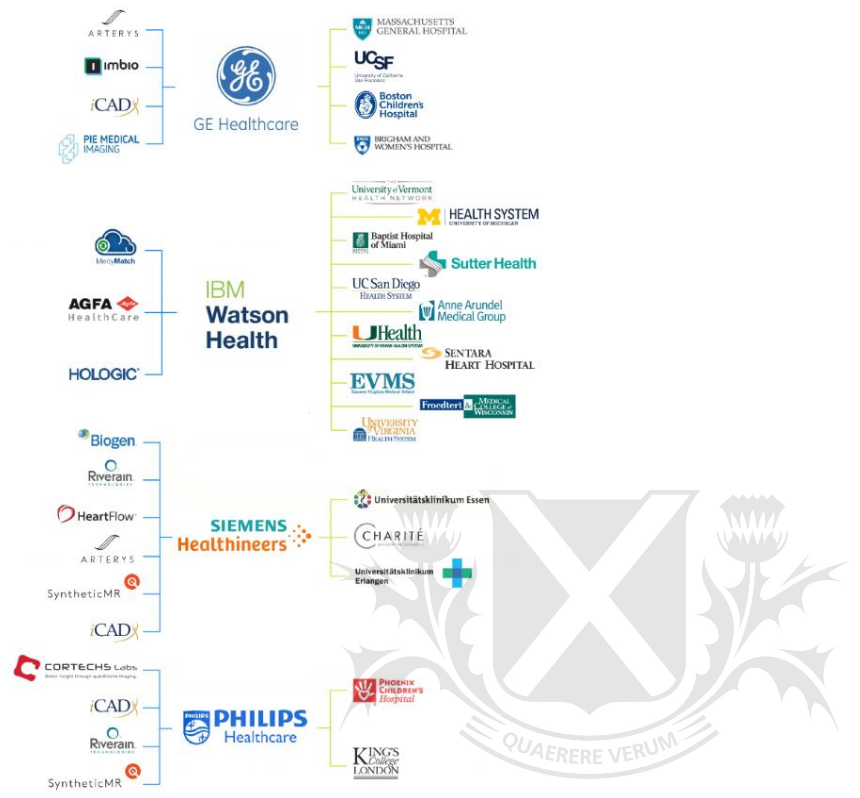
participantes (principalmente Google, IBM, Microsoft) han comenzado a realizar acuerdos estratégicos con instituciones académicas con el objetivo de contar con el acceso a datos a cambio de su financiamiento en investigación. Por otro lado, dado que la solución que realiza cada empresa suele atacar un caso de uso específico, se han comenzado a realizar acuerdos entre compañías para ampliar la oferta de servicios al cliente (Harvey, 2017).

Si bien cuentan con algunas soluciones propias (como es el caso de Siemens con *AI-Rad Companion Chest* CT[58]) todos parecen seguir una estrategia similar: una plataforma de IA que, si bien puede tener algún desarrollo propio, se nutre fundamentalmente de aplicaciones de terceros (Harris, 2018a).

Universidad de SanAndrés

58. Para más información: https://www.siemens-healthineers.com/infrastructure-it/artificial-intelligence/ai-rad-companion#top

Figura 31. Configuración del mercado.



Ref. Ejemplos de integración de grandes compañías (GE, IBM, Siemens, Philips) con Centros de salud y *startups*. - Fuente: *UK can lead in Radiology AI. Here's how*… (Harvey, 2017).

IBM es una de las grandes empresas que más esfuerzo está realizado para aplicar ML en DPI. Más allá de la importancia de contar con soluciones tecnológicas robustas, uno de los factores más importantes para el éxito de un proyecto es el acceso a grandes cantidades de datos representativos de lo que se quiera investigar y desarrollar. Es por esto que, en 2015, IBM ha adquirido la compañía Merge Healthcare, proveedora de un software de DPI. La misma cuenta con una base de datos de 30 billones de imágenes de pacientes, escenario ideal para la realización de entrenamientos de redes neuronales (Y. Wang et al., 2018).

3.8 Ecosistema de *startups*

Se estima que el ecosistema de *startups* está compuesto por poco más de 120 empresas, de las cuales su mayoría fue creada en los últimos 5 años. Del total de

startups, 83 han recibido inversiones, entre 2014 y 2018, de $762 millones de dólares[59], principalmente de capitales de riesgo y capitales privados. En la caracterización realizada, se agrupa las compañías por región del cuerpo en la que se encuentran trabajado. Cardiología, neurología, pulmones y mamas son áreas específicas en donde se encuentran actualmente trabajando (Harris, 2019).

Figura 32. Ecosistema de *startups* categorizada por región corporal.

Universidad de
SanAndrés

Ref: Mapa del ecosistema mundial de startups de servicios de ML para el DPI, clasificado por área de especialización. Se agrupa las compañías por región del cuerpo. Cardiología, neurología, pulmones y mamas son áreas específicas en donde se encuentran trabajando - Fuente: (Harris, 2018c).

En la conferencia 2018 de la RSNA las *startups* se encontraban enfocadas en lograr una mayor aceptación del mercado a través de la generación de un retorno de inversión para los prestadores de salud, ya sea mejorando la productividad de los profesionales o permitiendo diagnósticos y tratamientos más rentables. Algunos ejemplos de las soluciones actuales son:

59. Cifra estimada sin tener en cuenta las inversiones realizadas a la empresa HeartFlow, las cuales se estiman en aproximadamente $440 millones de dólares.

- Soluciones para tareas repetitivas y de gran volumen, como se da en el proceso de detección de cáncer.
- Soluciones *triage* que priorizan los casos urgentes en la lista de estudios pendientes a analizar.
- Soluciones que proveen mediciones automáticas, generando ahorros de tiempo en las mediciones realizadas por los profesionales (Harris, 2018a).

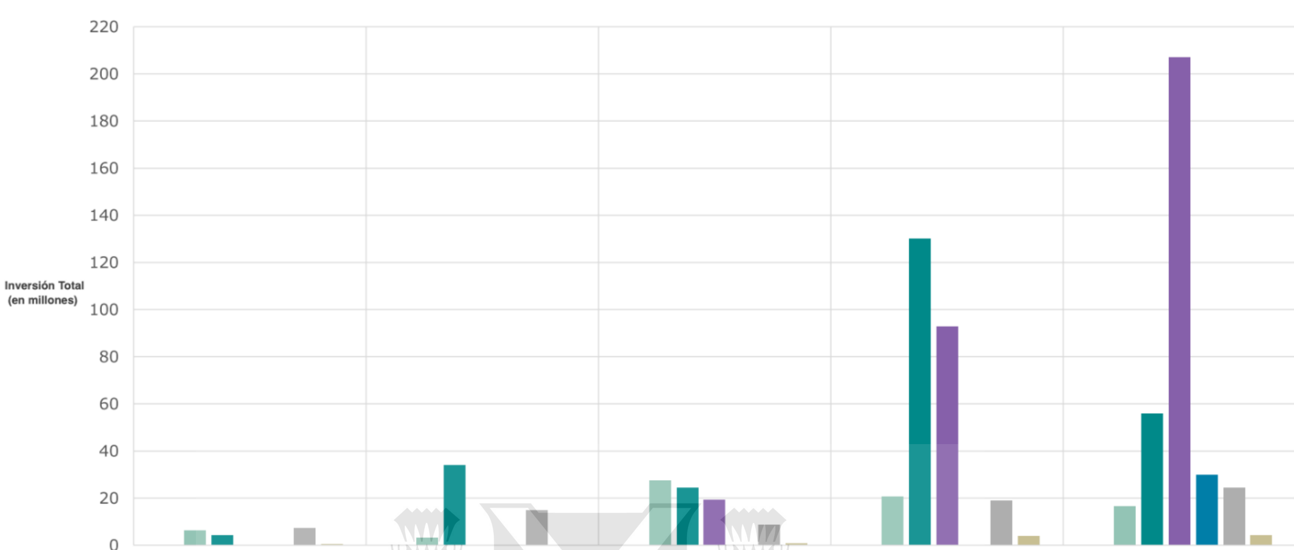
3.8.1 Inversiones en *startups*

En 2017 las inversiones en proyectos de ML para el análisis de imágenes han alcanzado los $240 millones de dólares. En 2018 se genera un nuevo crecimiento de inversiones, alcanzado los $340 millones de dólares[60].

Por otro lado, en 2018 se ha duplicado la inversión en las series B respecto al 2017. Alineado a esto, en 2018, los proyectos que se encuentran en una etapa temprana y han recibido algún tipo de inversión (Capital Semilla y Serie A) han disminuido de 29 a 15, respecto a 2017. De las 10 compañías que recibieron mayor cantidad de inversión, 5 son originarias de Estados Unidos y 4 de Asia. Solo una corresponde a Europa (Harris, 2019).

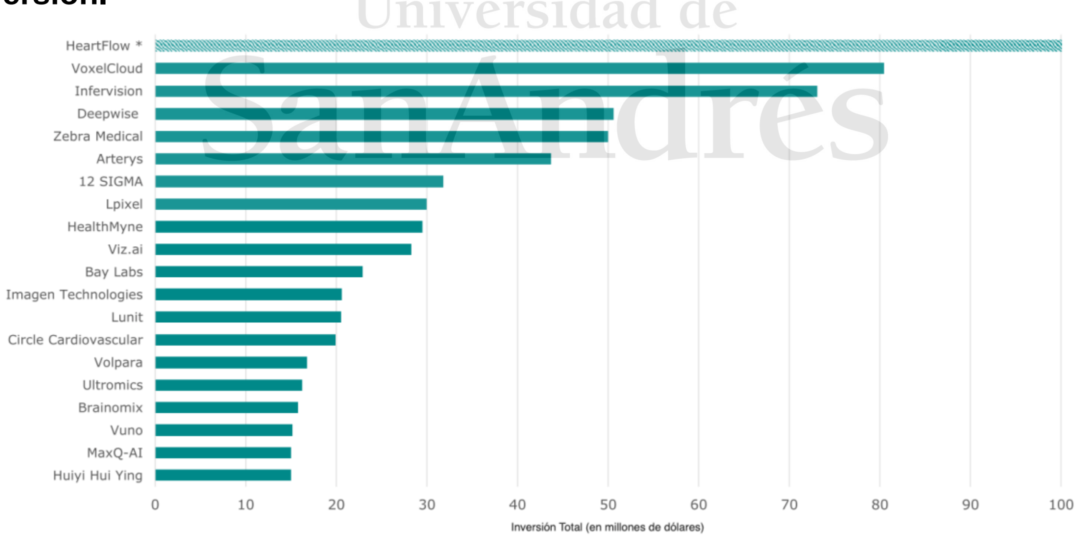
60. Cifra estimada sin tener en cuenta a la empresa HeartFlow, la cual ha recibido en 2018 una inversión de $240 millones de dólares.

Figura 33. Tipos de inversiones realizadas a *startups* de IA en imágenes.



Ref: Evolución de los tipos de inversión realizados en empresas de de productos basados en IA en imágenes. En el gráfico se puede observar el salto exponencial de inversiones entre 2016 y 2017. Respecto a 2017, en 2018 han aumentado las Serie B y disminuido las Serie A. - Fuente: Elaboración propia a partir de (Harris, 2019).

Figura 34. Top 20 de las empresas de IA en imágenes médicas con mayor inversión.



Fuente: (Harris, 2019).

3.8.2. Descripción de *startups*

A continuación, tomando en cuenta el relevamiento de *startups* elaborado por la consultora Signify Research, se realizará una descripción de algunas de las empresas con presencia en el mercado. El criterio de selección fue realizado tomando en cuenta inversión, funcionalidad, y grado de avance de sus proyectos.

Dado que se trata de empresas jóvenes y de nicho, hemos encontrado que actualmente la información acerca de las mismas es escasa.

3.8.2.1 Zebra Medical Vision

De acuerdo a la base de datos Crunchbase, Zebra Medical Vision[61] (en adelante, Zebra) es una compañía israelí fundada en 2014.

Según su sitio web, Zebra utiliza una base de datos propietaria con millones de estudios ya realizados e informados. La misma sigue creciendo gracias a los acuerdos de colaboración con grandes hospitales del mundo. De esa forma, la base de conocimiento de Zebra se va haciendo cada vez más grande.

El procesamiento de dicha información, a través de herramientas ML y DL, llevó a la compañía a la creación del algoritmo AI1[62] , a través del cual realiza:

- Detección de fracturas óseas.
- Análisis de mamografías.
- Priorización en el análisis de estudios en función de un triage inicial. Actualmente cubra los siguientes casos: hemorragias intracraneales en tomografías computadas y de neumotórax a través de una radiografía de tórax.

61. Para más información: https://www.zebra-med.com/

62. Para más información: https://www.youtube.com/watch?v=0PGgCpXa-Fs

Actualmente las soluciones se encuentran aprobadas por el CE, no así por la FDA (BusinessWire, 2018).

Zebra disrrumpió el mercado de la salud anunciando que cada uno de sus escaneos e informes tendrá el costo de un dólar (Munford, 2017).

La empresa ya posee tres patentes propias. La última de ellas, anunciada en febrero de 2019, hace foco en el análisis volumétrico de la densidad mineral en los huesos. Dicho análisis tiene una relación directa con la detección de la osteoporosis. Según el Congreso Mundial de Osteoporosis, 75% de las fracturas existentes no son detectadas en los estudios de imágenes o no son informadas. Los algoritmos de detección automática de Zebra permiten, en estudios de tomografía computada, la detección de la mayor parte de las facturas en pecho y abdomen. Estas detecciones tempranas permiten prevenir o posponer la fracturas asociadas a la osteoporosis y ahorrar al sistema de salud millones de dólares (BusinessWire, 2019).

Algunos de los beneficios que declara Zebra en su sitio web son:

- Identificar a los pacientes graves en forma temprana. El análisis de las imágenes permite a los centros de salud modificar la prioridad entre los estudios, pudiendo accionar en forma más temprana ante los casos que lo requieran.
- Facilitar programas de prevención de enfermedades. Permite a las instituciones de salud identificar a pacientes con riesgo de enfermedad y ofrecer mejores vías de tratamiento preventivo.
- Administrar programas de salud para reducir el costo de atención
- Análisis de hallazgos. La solución permite alertar al profesional de la existencia de hallazgos en las imágenes. Es decir, diagnósticos que aparecen en las imágenes que no fueron el motivo por el cual médico solicitó dicho estudio. Esto puede llevar a la detección temprana de enfermedades, lo que también lleva nuevamente a un acercamiento a la medicina preventiva.

Zebra ya ha tenido una inversión de $50 millones de dólares (Press, 2919).

3.8.2.2 Voxel Cloud

De acuerdo a la base de datos Crunchbase, Voxel Cloud[63] es una compañía estadounidense fundada en 2016 por Xiaowei Ding y Demetri Terzopoulos.

Según el sitio web de la empresa, el objetivo de la misma es ayudar a los profesionales a tomar decisiones de una manera más precisa accesible y eficiente. Para esto ofrecen algoritmos de análisis automático y soluciones *end-to-end.*

Según un reportaje que le ha hecho el medio MedGadget en 2017 a su CEO Xiaowei Ding, actualmente las soluciones con las que cuentan, todas basadas en la nube, están orientadas al análisis de tomografías computadas para la detección de cáncer de pulmón y enfermedades coronarias. Esta última cuenta con la aprobación de la FDA y de la CE.

Los otros dos productos se encuentran en fase de prueba, con el objetivo de conseguir la aprobación de la regulación China. Para esto, han realizado un acuerdo con más de cien centros médicos y hospitales en China (Hastings, 2017).

A la fecha, según la base de datos Crunchbase[64], la empresa tuvo un fondeo de $78 millones de dólares y es respaldada por grandes capitales de riesgo como Sequoia.

3.8.2.3 Viz

De acuerdo a la base de datos Crunchbase, Viz[65] es una compañía estadounidense fundada en 2016.

63. Para más información: http://www.voxelcloud.io/en/index.html

64. Para más información: https://www.crunchbase.com/organization/voxelcloud

65. Para más información: https://www.viz.ai/

Según el sitio web de la empresa, la misma posee un conjunto de productos que ayuda a los médicos en la toma de decisiones. Entre los productos basados en ML, se encuentran los siguientes:

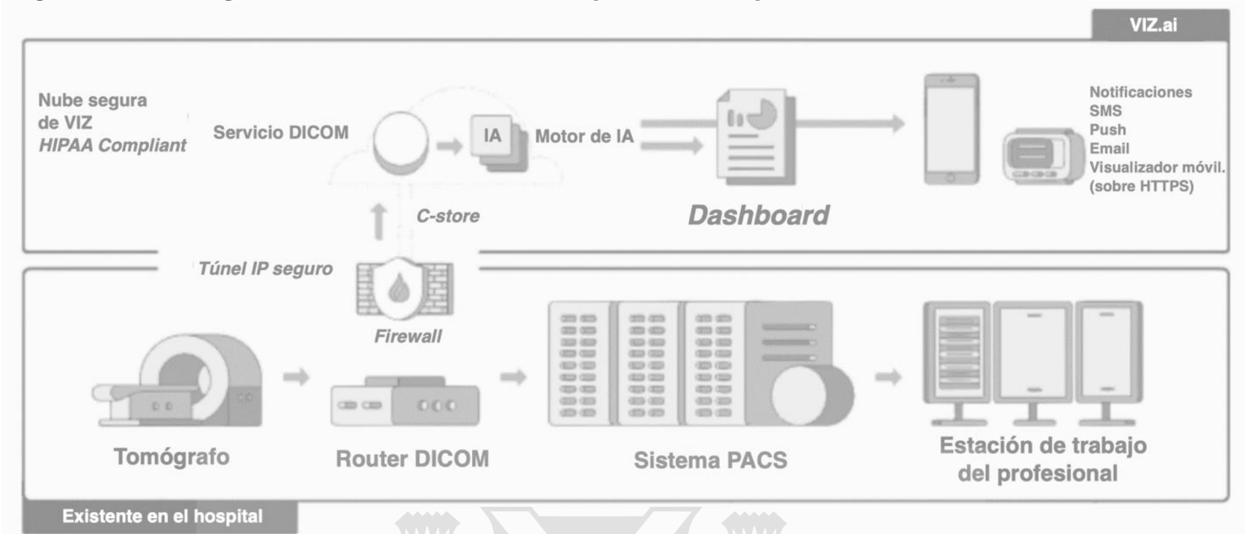
- *Viz. CTP*. Analiza automáticamente las imágenes generadas por el tomógrafo de perfusión del cerebro, produciendo mapa de colores a la par que realiza cálculos de los parámetros de perfusión[66].
- *Viz. LVO*. Esta herramienta detecta y alerta a los médicos de posibles accidentes cerebrovasculares por la oclusión de vasos sanguíneos pocos minutos después de haberse obtenido las imágenes del tomógrafo. Esto permite priorizar los casos según la gravedad de cada uno.

En el 2018 la empresa ha recibido la aprobación de la FDA para comercializar sus productos bajo la regulación con nombre, *Radiological Computer Aided Triage and Notification Software*. Algunos de los controles que le ha solicitado la FDA son: descripción de la solución y sus algoritmos; descripción de los datasets que se utilizaron para evaluar si el dispositivo proporciona una clasificación efectiva; resultados de las pruebas realizadas que demuestren la efectividad de la solución y documentación del producto (Sahiner, Pezeshk, & Petrick, 2018).

Uno de los beneficios a destacar que se evidencia en la Figura 35 es que no requiere cambios en procedimientos ni en los flujos de trabajo definidos. Por lo contrario, las soluciones de Viz complementan a los servicios ya existentes en los centros de atención

66. La perfusión es el pasaje de sangre, o de otro fluido, a través de los vasos sanguíneos u otro canal natural, en órganos o tejidos.

Figura 35. Integración de Viz.LVO al flujo de trabajo.



Ref: La gráfica muestra como el producto Viz.LVO se integra al flujo de trabajo sin modificarlo. Una vez que las imágenes del tomógrafo son adquiridas, son enviadas el Router DICOM, el cual las envía al sistema PACS. Por otro lado, las envía al servicio de Viz para realizar el análisis de los estudios, con el objetivo final de priorizarlos según la gravedad de los mismos. - Fuente: Sitio web de Viz.ai

A la fecha, según la base de datos Crunchbase[67], la empresa tuvo un fondeo de $31 millones de dólares y es respaldada por grandes capitales de riesgo como Kleiner Perkins y GV.

3.8.2.4 DiA Imaging Analysis

De acuerdo a la base de datos Crunchbase, DiA Imaging Analysis[68] es una compañía israelí fundada en 2009.

Según declara en su sitio web, la empresa provee herramientas basadas en reconocimiento de patrones y ML, optimizadas para ecógrafos pequeños y de mano, las cuales automáticamente imitan la forma que el ojo humano detecta bordes e identifica movimientos, brindando así una ayuda a los profesionales en la toma de decisiones.

67. Para más información: https://www.crunchbase.com/organization/viz

68. Para más información: https://www.dia-analysis.com/

LVivo cardiac es el primer conjunto de herramientas lanzado por la empresa. A diferencia de otras soluciones vistas anteriormente, funciona de manera *offline*. Es decir, no es necesario que se conecte a internet o a una infraestructura de tipo nube. Esto es fundamental ya que, a diferencia de otro tipo de estudios, como resonancias y tomografías, que suelen ser analizadas en forma posterior a la realización del estudio, las ecografías son analizadas *in situ*. Generalmente la práctica se desarrolla en consultorios, pero también en ambulancias y salas de emergencia. Por lo que no es deseable depender de la conectividad en esos momentos críticos.

La empresa firmó en 2017 un convenio con GE. A través del mismo LVivo cardiac ya se encuentra integrado con ecógrafos y sistemas de esa compañía. Pero este acuerdo no es de exclusividad, por lo que ya es posible utilizar esta solución con las marcas principales de ecógrafos y de PACS. Ese mismo año también firmó un acuerdo con Google Cloud para poder acceder a las herramientas desde cualquier sitio (Kyle Wiggers, 2018).

Figura 36. Ecógrafo de mano GE con Lvivo ya integrado.

Fuente: Sitio web de DiA Imaging Analysis.

QUAERERE VERUM Universidad de SanAndrés

A la fecha, según la base de datos Crunchbase[69], la empresa tuvo un fondeo de $12,1 millones de dólares y es respaldada por capitales de riesgo como Shengijing group, AltaIR Capital y CE Ventures.

3.9 El futuro de Machine Learning en DPI

La consultora Signify Research, ha elaborado un modelo de madurez de ML orientado al DPI. El mismo está basado en una tabla de doble entrada. Una dimensión corresponde a la madurez (Investigación - 2015 a 2016; Surgimiento - 2017 a 2018; Crecimiento - 2019 a 2023; Madurez - 2023 en adelante). La segunda dimensión corresponde a la descripción de cada una de las etapas (Evolución del producto; Relevancia Clínica; Vendedores; Validación Clínica; Integración a Flujos de Trabajo; Camino al mercado; Uso de Clientes) (Harris, 2018a).

Universidad de
SanAndrés

69. Para más información: https://www.crunchbase.com/organization/diacardio

Figura 37. Modelo de madurez de ML para el diagnóstico por imágenes.

	Stage 1 – Research (2015 to 2016)	Stage 2 – Emerging (2017 to 2018)	Stage 3 – Growth (2019 to 2023)	Stage 4 – Institutionalised (2023 onwards)
Product Evolution	1. Algorithms for research use only	1. Regulatory approved algorithms 2. Predominantly software applications 3. Point solutions 4. Mainly detection and quantification with limited decision support 5. Basic lesion characterisation	1. Software applications and embedded solutions 2. Body area solutions 3. Enhanced clinical decision support 4. Predictive capabilities 5. Automated reporting	1. Multi-organ, multi-modality solutions. 2. Whole body analysis 3. Automated diagnosis 4. Advanced decision support with genomics data
Clinical Relevancy	1. Clinical rather than commercial focus	1. Focus on radiologist efficiency and productivity 2. Repetitive, high-volume and time consuming tasks, e.g. cancer screening 3. Triage solutions 4. Quantification	1. 100s of apps for a wide range of clinical use-cases 2. Solutions for rare cases 3. Greater clinical use of imaging biomarkers 4. Personalised treatment decisions	1. Precision medicine 2. Virtual biopsy 3. Imaging AI combined with genomics 4. Imaging AI enables new clinical discoveries
Vendors	1. Medical AI start-ups 2. Academic spinouts 3. Medical image analysis specialists	As Stage 1 plus: 4. Incumbent medical imaging vendors 5. Big tech vendors, e.g. Google, Facebook, etc. 6. Life science companies	As Stage 2 plus: 1. Incumbents acquire successful AI start-ups 2. Start-up failures as VC investment becomes harder to obtain 3. Start-ups become less localised	1. Further market consolidation
Clinical Validation	1. Small-scale reader studies	1. Retrospective and prospective multi-reader studies	1. Large scale multi-site reader studies 2. Continuous learning from solutions deployed in the field 3. Validation by industry bodies, e.g. ACR	As Stage 3
Workflow Integration	1. Standalone workstations	1. Standalone workstations 2. Dedicated cloud-based AI platforms 3. Basic integration with imaging IT (PACS, viewers and AV)	1. Tight (overlay) integration with imaging IT 2. Integration with radiology worklists 3. Integration with EHR and other clinical systems 4. Emergence of edge AI on modalities	1. Single diagnostic platform (clinical, imaging and genomics) with fully integrated AI 2. Edge AI becomes pervasive
Route to Market	1. Direct sales by image analysis vendors 2. Licencing and co-marketing agreements between imaging vendors and medical AI startups	As stage 2 plus: 3. Launch of online medical imaging AI marketplaces	1. AI marketplaces gain traction 2. Basic AI tools are commoditised and become standard features of imaging IT platforms and modalities	1. Further commoditisation
Customer Use	1. Research projects	1. Pilots 2. Single care provider sites	1. Deployed across provider networks in developed healthcare markets around the world 2. Traction in single payer markets 3. Early use in emerging markets	1. Ubiquitous in developed markets 2. Growing use in emerging markets

Fuente: (Harris, 2018a).

QUAERERE VERUM
Universidad de
SanAndrés

En relación al mediano y largo plazo, Signify Research espera como hitos más importantes:

Etapa de Crecimiento (2019 - 2023)

- Cobertura. Las soluciones pasarán de tener la capacidad de caracterizar lesiones básicas y específicas a caracterizar lesiones de una parte del cuerpo, no solo cubriendo las enfermedades más comunes sino haciendo foco en los casos menos frecuentes.
- Rol del especialista en DPI. Se espera una mayor grado de independencia de su rol respecto a la realización del informe médico.
- Proveedores. Se espera una caída en la cantidad de empresas, dado un posible proceso de adquisiciones y baja en las inversiones a *startups* por parte de *Venture Capitals*.

- Flujo de trabajo. Las soluciones dejarían de existir independientes del flujo de trabajo y se integrarían al mismo y a otros sistemas, como la historia clínica. Por otro lado, se espera que los fabricantes de modalidades incluyan software basado en ML dentro de sus máquinas por lo que las soluciones de IA podrían entrar en una etapa de "*commodity*".
- Mercados emergentes. Las herramientas basadas en ML entrarían en una etapa de adopción en economías emergentes.

Etapa de Madurez (2023 en adelante)

- Cobertura. Se esperan soluciones integradas no con una, sino con múltiples modalidades de trabajo (resonador, tomógrafo, entre otros), pudiendo realizarse un análisis integral de todo el cuerpo humano.
- Rol del especialista en DPI. Se espera que no solo el informe sino todo el diagnóstico del paciente se realice sin su participación.
- Medicina de Precisión. Apoyado en el análisis del genoma humano se espera avances en la medicina personalizada, permitiendo también nuevos descubrimientos.
- Proveedores. Se espera una consolidación del mercado, concentrando las distintas soluciones en una menor cantidad de proveedores.
- Mercados Emergentes. Las soluciones basadas en ML entrarían en una etapa de crecimiento en economías emergentes y una masificación en las economías desarrolladas, percibiendo a las soluciones como un "*commodity*".

A continuación, habiendo concluído el Capítulo 3, realizaremos las conclusiones finales de nuestro trabajo de investigación.

CAPÍTULO 4 – Conclusiones

4.1 Repaso de los temas vistos

En el presente trabajo nos propusimos analizar la implementación de ML en el DPI.

A partir de esta propuesta, en el Capítulo 1, realizamos las siguientes tres preguntas de investigación:

- ¿Puede Machine Learning mejorar la precisión de resultados a la par de reducir los tiempos en Diagnóstico por Imágenes?
- ¿Se encuentra en riesgo, a corto y mediano plazo, la continudad laboral de los médicos especialistas a partir de la implementación de Machine Learning en Diagnóstico por Imágenes?
- ¿Existe una industria impulsando soluciones de Machine Learning en Diagnóstico por Imágenes?

Para arribar a los resultados obtenidos, hemos utilizado una metodología exploratoria y cualtitativa. Realizamos una triangulación entre nuestras fuentes primarias y secundarias, entre la que se destaca abundante bibliografía, una serie de entrevistas realizadas a expertos, la observación del trabajo del profesional y la concurrencia a eventos.

En el Capítulo 2, con el objetivo de brindar un marco teórico a nuestro trabajo se realizó una investigación de los conceptos de IA, ML y DL, centrándonos en sus arquitecturas utilizadas para el análisis de imágenes (RN y RNC). Luego enumeramos, en base a acuerdos celebrados en Europa y Estados Unidos, los aspectos éticos más importantes a tener en cuenta a la hora de realizar implementaciones de IA. Describimos a la Cuarta Revolución Industrial y su impacto

en la economía y el trabajo. Detallamos en qué etapas del proceso sanitario la IA puede aportar valor y cómo puede transferirse el mismo entre los actores del sistema en función de sus inversiones. Hicimos un análisis del accionar para alcanzar el mercado de IA en salud de Google, IBM, Apple, Facebook, Microsoft y Amazon. Por último, se realizó una caracterización de la especialidad y del profesional de DPI, repasando sus inicios, las modalidades principales, el uso de la teleradiología, la primera fallida ola de herramientas CAD, y los casos de uso posibles en todo el proceso llevado a cabo desde el área de DPI.

En el Capítulo 3 identificamos por qué se está comenzando a usar DL en DPI, sus aplicaciones dentro de la especialidad y cómo modifica actualmente el rol del profesional. Describimos los aspectos éticos y regulatorios más importantes y la problemática asociada a los *datasets*. A continuación, caracterizamos el mercado de ML en DPI y describimos algunas de las *startups* más importantes. Por último, detallamos la visión a futuro sugerida por la consultora Signify Research acerca del mercado de ML en el DPI.

Al finalizar este Capítulo, se brindan todas las referencias bibliográficas utilizadas para el desarrollo de nuestra tesis, concluyendo con tres anexos. En los primeros dos anexos A y B se detalla el perfil de cada uno de los entrevistados y las preguntas que funcionaron como conductoras de las entrevistas realizadas. Por último, en el anexo C se detallan otros tipos de IA existentes.

4.2 Conclusiones finales

A continuación, intentaremos dar respuesta a cada una de las preguntas de investigación que hemos realizado en el Capítulo 1.

4.2.1 Precisión de los resultados y mejoras en la productividad

Es arriesgado realizar hoy una afirmación universal a través de la cual aseguremos que los resultados que se pueden obtener utilizando herramientas basadas en ML

para el DPI son más precisos que el análisis e informe que podría realizar el especialista con mayor experiencia en la materia. Pero sí podemos afirmar que hay una marcada tendencia que indica que nos encontramos en esa dirección.

Dada la etapa de investigación y desarrollo en la que se encuentra la implementación de ML, sería necesario analizar este punto por cada una de las aplicaciones que se le da en DPI. Si se hace foco sobre algunos estudios, como es el caso de radiografías de fractura de muñeca, la tecnología ha llegado a una etapa avanzada, en donde el error del profesional (12,5%) ya es mayor que el que posee ML (6,1%). Por otro lado, en estudios como la detección de nódulos pulmonares, si bien los resultados de ML, en su mayoría, son más precisos que el de los especialistas, existen excepciones. Por ejemplo, en los nódulos semi sólidos de menos de 5 milímetros, la precisión de ML fue de 54,2%, mientras que la precisión obtenida por dos diferentes especialistas fue de de 62,5% y 75%.

Existe una mayoría de estudios sobre los que no se puede aseverar resultados, ya sea porque no hay publicaciones realizadas o simplemente porque los investigadores todavía no se han enfocado en dichas patologías.

Si bien es fundamental comprender en qué medida la tecnología aporta mejores resultados que los provistos por el más experimentado profesional, existe otro interrogante que consideramos también importante para seguir abordando la investigación de cara al futuro. La pregunta es, ¿el uso de ML en DPI permite a más pacientes acceder a resultados más precisos? Y nuestra respuesta es que sí, aplicando IA en general, y ML en particular, se puede brindar a más personas una mayor accesibilidad a mejores resultados. Esto está asociado al impacto que genera la IA en la democratización de la salud. Es decir, ampliar el acceso y generar una tendencia hacia la estandarización de su calidad.

Es importante remarcar que sería un error pensar a ML como la “bala de plata” para lograr avances en la democratización del DPI. Es decir, para alcanzar su potencial,

consideramos que ML debería pensarse como una solución integrada a otras tecnologías y al quehacer humano. Un ejemplo de tecnología complementaria es la teleradiología, mencionada en nuestro trabajo, la cual ya se encuentra implementada en forma masiva tanto en países desarrollados como emergentes. Utilizar ambas tecnologías en conjunto podría profundizar tanto accesibilidad como calidad. Así, un paciente que se realiza un estudio en cualquier lugar del mundo (por ejemplo, en un pueblo con escasa presencia de profesionales) podría tener acceso a los mismos resultados que en una gran ciudad, donde la cantidad de recusos suele ser mayor.

Por otro lado, en un escenario donde cada vez habrá una mayor cantidad de estudios para analizar, es necesario contar con herramientas que compensen la falta de médicos especialistas en DPI. Como hemos visto en el Capítulo 3, ML permitirá a los profesionales generar ahorros de tiempo en la confección del informe, gracias a la posibilidad de hacer más eficiente la detección de anormalidades, mediciones, comparación con estudios previos o realización de informes. Por otro lado, también permitirá disminuir el error causado por la sub-lectura (principalmente debido a la fatiga y objetivos exigentes sobre la cantidad de estudios informados) tal cual menciona el Dr. Diego Slezak en la entrevista realizada.

Si bien podemos afirmar que utilizando ML habrá una mejora en la productividad del profesional, ya sea por casos citados (como el estudio citado sobre nódulos pulmonares, en donde el procedimiento de 15 minutos ha tenido ahorros de entre 5 y 10 minutos) como así también por los argumentos teóricos que lo sugieren, la cantidad de investigaciones realizadas y resultados expuestos posee carácter escaso. Esto último, posiblemente, debido a la baja adopción actual asociada al poco tiempo en mercado que poseen las soluciones aprobadas. Teniendo en cuenta los problemas que surgieron con la primera fallida ola de herramientas CAD, en donde se han registrado aumentos del 20% en el tiempo de análisis de imágenes, consideramos que es necesario continuar profundizando el tema.

Por lo tanto, cuantificar el ahorro de tiempos será trabajo de futuras investigaciones. Al igual que en el análisis de precisión de resultados, dado la gran magnitud de escenarios existentes, no será posible realizar una respuesta única. Se deberá analizar, medir e informar por cada uno de los casos de uso.

4.2.2 ¿Complemento o reemplazo del médico especialista?

Referentes de ML, como Geoffrey Hinton, han despertado el temor por parte de los profesionales, sugiriendo que no habría que entrenar más a médicos especialistas en DPI ya que en poco tiempo no serían indispensables.

A partir de nuestra investigación podemos concluir que la posición del especialista, a mediano plazo, continuará existiendo. Es decir, el peligro a ser desplazado, en dichas ventanas de tiempo es prácticamente inexistente. Existen motivos de sobra para arribar a esta conclusión.

En principio, la implementación de la tecnología se encuentra en una etapa de adopción temprana. Esta inmadurez se puede evidenciar en los siguientes puntos:

- **Baja cobertura de escenarios investigados**. La mayor parte de casos y patologías existentes no han sido abordados para su investigación y desarrollo. Por otro lado, la mayor parte de los casos que han sido desarrollados por empresas tecnológicas no posee todavía la aprobación para su uso comercial.
- **Alcance de las soluciones**. Las soluciones desarrolladas por las empresas tecnológicas atacan muy pocos casos de uso. En un escenario generalizado como este, si el prestador de salud quisiera contar con una solución integral, debería incurrir en la contratación de múltiples soluciones. Más allá del costo económico que esto podría generar, existe un problema asociado a la cantidad de interfases e integraciones que habría que realizar entre los distintos sistemas, algo que no pareciera viable.

- **Alto costo de entrenamiento.** Si bien es inmensa la cantidad de imágenes existentes para realizar entrenamientos de algoritmos, esto no es suficiente ya que la mayor cantidad que hoy se encuentra disponible no ha sido etiquetada de la manera que se requiere para poder realizar esta tarea. Dado el alto costo que posee el etiquetado, debido al tiempo que lleva realizarlo como así también a los recursos humanos necesarios, esta etapa funciona como una barrera de entrada, lo que haría lenta la llegada de soluciones al mercado. Por este motivo, algunos prestadores de servicios de DPI están comenzando a informar y almacenar sus imágenes, de manera tal, que las mismas puedan ya estar listas para ser utilizadas en futuros entrenamientos de algoritmos.
- **Consentimiento del paciente**. Cada estudio de imágenes que compone el *dataset* que se presente ante el ente regulador para la aprobación de una solución debe contar con el consentimiento del paciente. Si bien el prestador de salud almacena cada estudio, el único dueño de la información es el paciente. Ante esta barrera de entrada, es imperioso que los prestadores de salud comiencen a solicitar la firma de dichas autorizaciones para que las empresas de tecnología puedan avanzar con la prueba y aprobación de sus proyectos, por parte de los entes reguladores

Existe otra serie de motivos por los cuales el especialista en DPI continuaría siendo el pilar en el proceso de análisis de imágenes:

- **Mejores resultados**. Como hemos visto en el Capítulo 3 a través de una serie de ejemplos, y tal vez uno de los puntos clave, los mejores resultados obtenidos no han surgido de las soluciones de ML sino del concepto del centauro. Es decir, de la combinación de IA y de la inteligencia humana. Es el caso, por ejemplo, de los estudios de detección de nódulos pulmonares, en donde el binomio médico-ML ha obtenido, en algunos casos, una precisión del 100%.

- **Aspectos éticos**. Entre los referentes entrevistados no hay un consenso en cuanto a la verdadera importancia de realizar una decodificación de la llamada Caja Negra (la cual no permite comprender cómo ha resultado el algoritmo un determinado problema, es decir, no permite comprender la forma en que se ha arribado a una decisión). Mientras la misma se mantenga cerrada será difícil garantizar no incurrir en sesgos que afecten a sectores de la población. Si bien la última palabra la tendrán los entes reguladores, consideramos que al igual que un profesional, una solución autónoma de ML debería poder explicar el por qué en la toma de una decisión ya que, de lo contrario, la falta de respuesta atenta contra la transparencia y la equidad, aspectos detallados por algunos de los acuerdos de ética mencionados en el Capítulo 2.

- **Aspectos legales.** Dado que a la fecha la especialdiad de DPI no possee ninguna solución autónoma, el profesional seguirá siendo el responsable legal sobre el trabajo producido por el binomio médico-máquina. Si dicha autonomía fuera alcanzada, todo indica que la responsabilidad recaerá sobre otros actores (como podrían ser la empresa de desarrollo de software o el prestador del servicio). Si bien existe en el mercado una solución oftalmológica autónoma, aprobada por la FDA, que podría tomarse como referencia, no se conocen antecedentes que nos permitan saber el accionar de la justicia.

- **Confianza.** Para que las soluciones de ML puedan operar con autonomía, los pacientes deben contar con información suficiente y resultados concluyentes. De esta manera, podrían aceptar ser examinados y diagnosticados por una máquina. Mientras esto no suceda, no importarán los avances tecnológicos o los aspectos éticos y regulatorios, el binomio médico – máquina será el lugar en donde se deposite toda la confianza.

Si bien consieramos que el puesto del médico especialista continuará siendo un pilar fundamental en la actividad del DPI, se debe volver a diseñar al mismo para así poder adaptarse de la mejor manera a los cambios que el sistema de salud requiere. Alineados a las palabras del Dr. Bertalán Mesko, consideramos que, si existiese la posibilidad de que los especialistas en DPI sean reemplazados, no sería, exactamente, por una máquina. Ese reemplazo estaría dado por otro profesional que hubiera adoptado ML para optimizar los tiempos dedicados a cada estudio y a la calidad de los resultados.

Para realizar el nuevo diseño del puesto de trabajo, como hace referencia el Dr. Luna en el Capítulo 2, el proceso debe pensarse desde los inicios de la formación universitaria. Los profesores universitarios deberán poder contar con la capacitación necesaria y con una bibliografía adaptada al perfil que se desea desarrollar. En base a las nuevas habilidades que requerirá el puesto, los planes de estudio tendrán que volver a desarrollarse de manera que el vínculo de los alumnos y los médicos con las tecnologías sea cada vez más sólido. ¿Qué es IA, ML y DL? ¿Cómo esta tecnología se utiliza para realizar detección y diagnóstico? ¿Qué lógica está utilizando para arribar a una conclusión? ¿Qué lugar ocupa el profesional médico en el entrenamiento de algoritmos? ¿Qué nuevos puestos de trabajo se deberán cubrir en base a los cambios en los procesos? Preguntas como estas deberían poder ser respondidas por los profesionales en el futuro.

Por último, también quisieramos que se tenga en cuenta que, si bien los médicos deberán realizar un acercamiento a la tecnología, los profesionales que provinene del mundo tecnológico tendrán que, por contrampartida, generar un acercamiento al mundo de la salud. Y ese acercamiento también debe tener su correlato en los planes de estudio universitarios.

4.2.3 La industria de empresas de ML en DPI

La industria de empresas desarrolladoras de ML en DPI se encuentra en los comienzos de una etapa de crecimiento. Consideramos que esto es así ya que, al observar la actividad particular de cada empresa, se puede evidenciar que los casos de uso cubiertos, tanto en los productos aprobados para su comercialización como los que todavía no lo están, son una mínima porción de la amplia variedad de análisis que realizan actualmente los médicos especialistas en DPI. Y es razonable, entendiendo el escaso tiempo en el mercado y el costo asociado a la investigación de cada cada patología.

Según los informes vistos en el Capítulo 3, se espera que el mercado crezca significativamente en los próximos años, alcanzando para 2022 un mercado de $2 billones de dólares.

Dicha industria se encuentra compuesta, principalmente, por tres grupos: los grandes capitales del sector tecnológico, los grandes capitales del sector de salud, y un ecosistema de *startups*.

Los grandes capitales del sector tecnológico (principalmente Google/Alphabet, IBM y Microsoft) aparecen en la escena, a través de desarrollos propios, con adquisiciones o en sociedad con empresas del sector, como así también con herramientas que facilitan el desarrollo de proyectos (como es el caso de Google con su framework, Tensorflow). Su posibilidad de realizar grandes inversiones, su experiencia en proyectos innovadores y su capacidad de adaptarse a nuevos escenarios hacen que puedan posicionarse como candidatos a dominar el mercado.

Los grandes capitales del sector de la salud (entre los que se destacan GE, Siemens y Philips) son aquellos que desempeñan el rol de fabricantes y proveedores de equipamiento médicos (principalmente resonadores, tomógrados, ecófgrafos y equipos de rayos x). Entendemos que tienen una posición dominante en el mercado dado que sus equipos se encuentran instalados en todas las áreas de DPI. Este

escenario los posiciona en un lugar estratégico, ya que cuentan con la posibilidad de integrar soluciones propias o de terceros a sus equipos. A modo de ejemplo, podemos citar el caso de la empresa Dia Image Analysis, que posee actualmente su servicio integrado en una serie de ecógrafos portátiles de GE[70]. Si este tipo de prácticas se extiende, resulta crítico que las *startups* y los grandes capitales del sector tecnológico logren acuerdos con estas de manera tal que se fortalezcan sus posiciones en el mercado.

El ecosistema de *startups* se encuentra desarrollándose principalmente en Estados Unidos, Europa y algunos países de Asía y está compuesto por cientos de emprendimientos creados en los últimos cinco años y nacidos generalmente como un desprendimiento de investigaciones académicas. En esta investigación consideramos que nos encontramos ante la usina de producción que sostiene el crecimiento del sector. Llegamos a esta conclusión debido a los siguientes motivos:

- **Acreedoras de grandes inversiones**. Como hemos visto en el Capítulo 3, en 2017 y 2018 las inversiones a las *startups* han aumentado exponencialmente respecto a años anteriores, llegando a tener en los últimos 5 años, una inversión promedio de poco más de $9,2 millones de dólares. Esto nos permite comprender que las *startups* necesitan y están recibiendo una fuerte inversión, utilizada fundamentalmente para potenciar las investigaciones. Por otro lado, la confianza se vio revalidada entre el 2017 y el 2018. En el primero, la mayor cantidad de inversiones fue realizada en rondas de Serie A. Esto cambia en 2018, bajando las inversiones de Serie A y duplicándose, en contraposición, las inversiones en Series B. Es decir, los inversores profundizan su realción con las *startups*, apostando a su desarrollo.
- **Componentes de producto integrador.** Vemos dificultoso que un prestador de salud contrate decenas de soluciones dado que esta decisión implicaría

70 Para más información: https://venturebeat.com/2018/08/06/dia-imaging-analysis-raises-5-million-for-ai-that-analyzes-ultrasound-scans/

incurrir en múltiples interfaces y posibles flujos de trabajo. Por otro lado, a pesar de que muchas de estás han logrado atraer grandes inversiones, consideramos que las sumas recibidas (y principalmente el acceso a datasets) limitarán la cantidad de investigaciones en las que se puedan enfocar. Por ambos motivos, el enfoque que podrían tener las *startups* es el del desarrollo efectivo de unos pocos escenarios que les permitan realizar un *exit.* Es decir, ser finalmente adquiridadas por grandes capitales tecnológicos o de la industria de la salud. Consideramos que son los grandes capitales quienes tienen la posibilidad de sumar soluciones de terceros a plataformas integradoras, para así ofrecer al mercado productos o servicios con una amplia cobertura de escenarios.

Para entender cómo continuará desarrollándose la industria de cara al futuro queda pendiente, a medida que la adopción de la tecnología vaya sucediendo, demostrar tanto a los clientes como al mercado, que las soluciones de ML generan un beneficio económico tal que el retorno de la inversión alcance las expectativas. Como ya hemos mencionado en estas conclusiones, ese beneficio económico estará impulsado, sobre todo, por la mejora en la precisión de los resultados.

Para concluir consideramos importante tener en cuenta que, dado el auge reciente de la tecnología de ML en DPI, la industria no está exenta de transitar caminos sinuosos o fallidos. El motivo principal es que, si bien los resultados de las investigaciones han sido satisfactorios, en una gran medida, no se ha llegado a una etapa avanzada en el ciclo de adopción de los productos tal que garantice éxitos y permanencias de las empresas. Además, se encuentra latente la posibilidad de que, como ha dicho el Dr. Luna en la entrevista realizada, la soluciones basadas en IA ingresen a un tercer invierno, caracterizado por una reacción social ante la desconfianza de su uso.

4.3 El futuro de ML en DPI

Asegurar lo que sucederá a largo plazo con la implementación de ML en DPI sería adentrarnos en predicciones. Dado que nos encontramos realizando un trabajo científico, no es nuestro fin vaticinar sobre los posibles futuros. Sin embargo, nos tomaremos una licencia para dar una breve opinión sobre algunos puntos.

- **Dilema de la caja negra.** Se profundizarán las investigaciones y se logrará dar visibilidad acerca de cómo los algoritmos de DL toman cada una de sus decisiones. Esto permitirá reducir cualquier duda en relación a la posibilidad de incurrir en sesgos o errores.
- **Aprendizaje continuo.** Se alcanzará un alto nivel de madurez en la regulación de las soluciones de ML, lo que permitirá, entre otras cosas, desbloquear uno de los principales beneficios que posee ML y de la cual hoy no se goza: el aprendizaje *on line* de los algoritmos.
- **Mejores arquitecturas de redes neuronales.** Se desarrollarán nuevas arquitecturas de RN y se comprenderá en qué problemáticas deberán ser implementadas. De esta manera la precisión de los algoritmos continuará mejorando.
- **Reducción de costos de investigación.** Una gran cantidad de imágenes, sino todas, tendrá la aprobación por parte del paciente para su uso en investigación. Por otro lado, a la hora de informar, los profesionales lo haran de manera tal que el estudio quede disponible para un futuro entrenamiento. Esto hará reducir significativamente el esfuerzo en investigación como así también el *time to market.*
- **Profundización del acceso a la salud.** A partir de la posibilidad de realizar investigaciones de patologías complejas y poco habituales de forma económica, más personas podrán acceder a salud de alto nivel, impactando en forma directa en su esperanza y calidad de vida.

- **Mayor nivel de autonomía.** Las soluciones de ML habrán demostrado que sus resultados son confiables, tanto para los profesionales como para los pacientes, de manera que tendrán una mayor independencia del profesional. Las soluciones autónomas comenzarán a ganar más terreno, lo que generará un cambio radical en la forma de brindar servicios de salud y en el rol del médico especialista.
- **Condiciones de las aseguradoras.** Con el objetivo de reducir sus costos en la prestación de prácticas de salud, las aseguradoras exigirán a sus prestadores la implementación de soluciones de ML.
- **Nuevo estandar del mercado.** Los fabricantes de modalidades contarán con soluciones de ML ya integradas a su hardware.

4.4 Recomendaciones para futuras investigaciones

En el presente trabajo, como se indica en el Capítulo 1, hemos realizado un abordaje con una metodología exploratoria. Consideramos que fue un enfoque acertado ya que las herramientas de ML para el DPI se encuentran en una etapa de adopción temprana, surgiendo la mayor parte de los emprendimientos hace no más de cinco años. Este escenario impactó directo en nuestra investigación dado que, si bien hemos logrado consultar una gran cantidad de fuentes primarias y secundarias, en algunos puntos específicos la misma resultó escasa.

Consideramos a esta tesis de maestría como una primera aproximación al dominio en cuestión. Es decir, no la vemos como un punto de llegada sino como el inicio de un camino que recién se emprende.

Por tal motivo, sugerimos que la investigación continúe a medida que vayan surgiendo soluciones comerciales que permitan realizar casos de estudio, los cuales deberían aportar una visión cuantitativa e integral. De cada uno recomendamos investigar:

- La precisión que están alcanzando los clientes en las implementaciones de la solución.
- El grado de eficiencia que logran los prefesionales, como principales usuarios de los sistemas.
- El nivel de autonomía que poseen las soluciones respecto al rol del profesional.
- El impacto económico en los prestadores de salud y las aseguradoras.
- La posible transferencia de valor generada entre los distintos actores del sistema de salud.

Asimismo, es importante conocer cómo se irá transformando el ecosistema de *startups*, comprendiendo si efectivamente el mercado terminará concentrándose en pocos grandes jugadores.

Para finalizar, dado que esta tesis fue realizada desde una mirada de negocios, recomendamos también abordar futuras investigaciones desde el punto de vista de especialistas en aspectos tecnológicos, médicos, legales, éticos, regulatorios y educativos. De esa manera, lograremos tener miradas interdisciplinarias y complementarias del dominio, las cuales aportarán un grado de profundidad y comprensión aún mayor.

BIBLIOGRAFÍA

Aboshiha, B. A., Gallagher, R., & Gargan, L. (2019). Chasing Value As AI Transforms Healthcare.

Abramoff, M. D. (2018). FTC Hearing # 7, on Algorithms, Artificial Intelligence, and Predictive Analytics Panel: Understanding Algorithms, Artificial Intelligence, and Predictive Analytics Through Real World Applications.

Adam Conner-Simons, R. G. (2019). Using AI to predict breast cancer and personalize care. *MIT News*. Retrieved from http://news.mit.edu/2019/using-ai-predict-breast-cancer-and-personalize-care-0507

Agrawal Ajay, Gans, J., & Goldfar, A. (2018). *Prediction Machines*. Harvard Business Review Press.

Alfonseca, M. (2019). Inteligencia Artificial o IA. Retrieved from https://searchdatacenter.techtarget.com/es/definicion/Inteligencia-artificial-o-AI

Alpaydin, E. (2014). Introduction to Machine Learning. (The MIT Press, Ed.) (Third Edit).

Alzheimer´s Association. (2019). ¿Qué es el Alzheimer? Retrieved from https://www.alz.org/alzheimer-demencia/que-es-la-enfermedad-de-alzheimer

Ana Inés Basco, Gustavo Beliz, Diego Coatz, P. G. (2018). *Industria 4.0*.

Apple. (2019). Institutions that support health records on iPhone (beta). Retrieved from https://support.apple.com/en-us/HT208647

Apple Newsroom. (2019). ECG app and irregular heart rhythm notification available today on Apple Watch. Retrieved from https://www.apple.com/ee/newsroom/2019/03/ecg-app-and-irregular-rhythm-notification-on-apple-watch-available-today-across-europe-and-hong-kong/

Ardila, D., Kiraly, A. P., Bharadwaj, S., Choi, B., Reicher, J. J., Peng, L., … Shetty, S. (2019). End-to-end lung cancer screening with three-dimensional deep learning on low-dose chest computed tomography. *Nature Medicin*e. https://doi.org/10.1038/s41591-019-0447-x

Arsene, C. (2018). Healthcare executives: Don’t fear Artificial Intelligence. Embrace it. *Health Further*. Retrieved from https://www.healthfurther.com/the-future-of-health/2018/05/11/healthcare-executives-dont-fear-artificial-intelligence-embrace-it-icphcex/?utm_source=carsene&utm_medium=contributor&utm_campaign=18audiencegrowth

Batarekh, A., Preece, A. D., Bennett, A., & Grogono, P. (1991). Specifying an expert system. *Expert Systems With Applications*, *2*(4), 285–303. https://doi.org/10.1016/0957-4174(91)90036-E

Beaver, L. (20118). DIGITAL HEALTH BRIEFING: Alphabet, Apple, Microsoft patents reveal health interest — NHS staff in trouble for using chat apps — Google uses expert opinion to improve AI. *Business Insider*. Retrieved from https://www.businessinsider.com/digital-health-briefing-alphabet-apple-microsoft-patents-reveal-health-interest-nhs-staff-in-trouble-for-using-chat-apps-google-uses-expert-opinion-to-improve-ai-2018-3

Berlin, L. (2007). Radiologic Errors and Malpractice: A Blurry Distinction. American Journal of Roentgenology, 189(3), 517–522. https://doi.org/10.2214/AJR.07.2209

Bishop, T. (2017). One year later, Microsoft AI and Research grows to 8k people in massive bet on artificial intelligence. *Geek Wire*. Retrieved from https://www.geekwire.com/2017/one-year-later-microsoft-ai-research-grows-8k-people-massive-bet-artificial-intelligence/

Board of the Faculty of Clinical Radiology. (2018). Clinical radiology UK workforce census 2017 report. The Royal College of Radiologists, (September), 40. Retrieved from https://www.rcr.ac.uk/system/files/publication/field_publication_files/bfcr185_cr_census_2017.pdf

Bostrom, N., & Yudkowsky, E. (2011). The Ethics of Artificial Intelligence, 1–20. https://doi.org/10.1017/CBO9781139046855.020

Broussard, M. (2018). *Artificial Unintelligence How Computers Misunderstand the World*. MIT Press.

Brownlee, J. (2019). A Gentle Introduction to Computer Vision. Retrieved from https://machinelearningmastery.com/what-is-computer-vision/

Business Wire. (2019). Zebra Medical Vision Adds a 3rd Patent to Its Growing Bone Health Portfolio. *Business Wire*. Retrieved from https://www.businesswire.com/news/home/20190405005092/en/Zebra-Medical-Vision-Adds-3rd-Patent-Growing

Business Wire. (2018). Zebra Medical Vision Announces CE Approval of Its Newest AI Imaging Algorithm - Automatic Identification of Brain Bleeds. *Business Wire*. Retrieved from https://www.businesswire.com/news/home/20180305005693/en/Zebra-Medical-Vision-Announces-CE-Approval-Newest

Castellino, R. A. (2005). Computer aided detection (CAD): An overview. *Cancer Imaging*, *5*(1), 17–19. https://doi.org/10.1102/1470-7330.2005.0018

CBRA. (2013). *New Drug Development Process*. *California Biomedical Research Association*. Retrieved from https://www.google.co.in/search?q=505(b)(1)+approval+process&rlz=1C1CHWA_enIN613IN613&espv=2&biw=1366&bih=667&site=webhp&source=lnms&tbm=isch&sa=X&ved=0ahUKEwjMksKjj7vMAhUUBY4KHcnPBHcQ_AUICCgD#imgrc=UQE5X4NZom9IaM%3A

Chace, C. (2015). *Surviving AI*.

Chartrand, G., Cheng, P. M., Vorontsov, E., Drozdzal, M., Turcotte, S., Pal, C. J., … Tang, A. (2017). Deep Learning: A Primer for Radiologists. *RadioGraphics*, *37*(7), 2113–2131. https://doi.org/10.1148/rg.2017170077

Chockley, K., & Emanuel, E. (2016). The End of Radiology? Three Threats to the Future Practice of Radiology. *Journal of the American College of Radiology*, *13*(12), 1415–1420. https://doi.org/10.1016/j.jacr.2016.07.010

Chou, K. (2017). Partnering on machine learning in healthcare. *Google*. Retrieved from https://blog.google/technology/ai/partnering-machine-learning-healthcare/

Collier, M., Fu, R., Yin, U., & Christiansen, P. (2017). Artificial Intelligence: Healthcare´s New Nervous System, 1–8.

Cook, T. D., Reichardt, C. S., Manuel, J., & Guillermo (trad.) Solana. (1986). Métodos cualitativos y cuantitativos en investigación evaluativa. Madrid: Morata.

D’Onfro, J. (2018). Alphabet’s bets on health tech are paying off as portfolio companies go public. *CNBC*. Retrieved from https://www.cnbc.com/2018/03/30/alphabet-gv-life-sciences-and-health-investments-going-public.html

Dankhe, G. (1986). Metodología de la investigación. Definición del tipo de investigación.

Deep Learning Analytics. (2018). Deep Learning for Computer Vision – Image Classification, Object Detection, Object Tracking. Retrieved from https://deeplearninganalytics.org/deep-learning-computer-vision/

Denzin, N. K. (1989). *La ley de investigación: una introducción teórica a métodos sociológicos*. Prentice Hall (Englewood Cliffs, NJ).

Dolan, B. (2011). Official: Google Health shuts down because it couldn't scale adoption. *Mobi Health News*. Retrieved from https://www.mobihealthnews.com/11453/official-google-health-shuts-down-because-it-couldnt-scale

Dumont, C. A., Monserrat, L., Soler, R., Rodríguez, E., Fernández, X., Peteiro, J., … Castro-Beiras, A. (2007). Significado clínico del realce tardío de gadolinio con resonancia magnética en pacientes con miocardiopatía hipertrófica. Revista Espanola de Cardiologia, 60(1), 15–23. https://doi.org/10.1157/13097921

Dunn, P. M. (2001). Wilhelm Conrad Röentgen (1845-1923), the discovery of x rays and perinatal diagnosis Wilhelm Conrad Röentgen (1845 – 1923), the discovery of x rays and perinatal diagnosis, (December), 138–140. https://doi.org/10.1136/fn.84.2.F138

Erickson, B. J., Korfiatis, P., Kline, T. L., Akkus, Z., Philbrick, K., & Weston, A. D. (2018). Deep Learning in Radiology: Does One Size Fit All? *Journal of the American College of Radiology*, *15*(3), 521–526. https://doi.org/10.1016/j.jacr.2017.12.027

European Group on Ethics in Science and New Technologies. (2018). Artificial Intelligence, Robotics and "Autonomous" Systems Statement on European Group on Ethics in Science and New Technologies. https://doi.org/10.2777/786515

Farr, C. (2019). The inside story of why Amazon bought PillPack in its effort to crack the $500 billion prescription market. *CNBC*. Retrieved from https://www.cnbc.com/2019/05/10/why-amazon-bought-pillpack-for-753-million-and-what-happens-next.html

FDA. (2019). Proposed Regulatory Framework for Modifications to AI/ML-Based SaMD - Discussion Paper and Request for Feedback, 1–20. Retrieved from https://www.fda.gov/downloads/medicaldevices/deviceregulationandguidance/guidancedocuments/ucm514737.pdf.

Firmino, M., Angelo, G., Morais, H., Dantas, M. R., & Valentim, R. (2016). Computer-aided detection (CADe) and diagnosis (CADx) system for lung cancer with likelihood of malignancy. *BioMedical Engineering Online*, *15*(1), 1–17. https://doi.org/10.1186/s12938-015-0120-7

Forbes. (2019). Forbes - AI And Healthcare: A Giant Opportunity. Retrieved from https://www.forbes.com/sites/insights-intelai/2019/02/11/ai-and-healthcare-a-giant-opportunity/#3c57a7964c68

Forbes. (2019). Can You Sue An Algorithm For Malpractice? Retrieved from https://www.forbes.com/sites/insights-intelai/2019/02/11/can-you-sue-an-algorithm-for-malpractice/#236293e37013

Forsyth, R. (1984). *The Architecture of Expert Systems. In: Forsyth, R.S. (ed.) Expert Systems: Principles & Case Studies*. London: Chapman & Hall Ltd., pp. 9-17.

Frenk, J., & Gómez-Dantés, O. (2001). La democratización de la salud. Una visión para el futuro del sistema de salud en México. *Gaceta Medica de Mexico*, *137*(3), 281–287.

Frey, C. B., & Osborne, M. A. (2013). The Future of Employment: How Susceptible Are Jobs To Computerization? 1–72.

Future of Life Institute. (2017). Asilomar principles.

Gagliardi, A. (1990). Preston M. Hickey, 235–236.

Gardner, H. (1983). *Frames of Mind: The Theory of Multiple Intelligences*.

Garrido, F. (2009). *Determinantes de la calidad de vida percibida por los ancianos de una residencia de tercera edad en dos contextos socioculturales diferentes, España y Cuba*. Retrieved from http://www.albayan.ae

Gartner. (2018). Hype Cycle for Emerging Technologies, 2018. Retrieved from https://www.gartner.com/technology/media-products/reprints/ntt_com/340159.html?mkt_tok=eyJpIjoiWlRFM05tSTVNelE1WVRVMSIsInQiOiJQaWZFZ1dEVUVkNWpmWHBtRjNYb3h4bWFqOFhRUnI2WkZjY3JYZ0hcLzl4MXlTM1lOdmFEQ0ZobkdtckUrMkU3R1FrTkV3aEZBTncwVkQwNzNhSklCaXlGNDcrbnpaVTJC

Gazabón, G. G. (2014). Tesis de grado gisela garcia gazabón.

GE. (2018). *AI in Healthcare: Keys to a Smarter Future*. Retrieved from https://www.gehealthcare.com/-/media/b3a5e32538454cf4a61a4c58bd775415.pdf

Goodfellow, I. (2015). Deep Learning.

Grand, A. Le. (2017). Watson Imaging Clinical Review.

Green, A., & Holloway, S. (2019). Signify Research Show Report from HIMSS 2019. Retrieved from www.signifyresearch.net

Guinovart, J. (1998). Fundamentos de Lingüística Computacional: bases teóricas, líneas de investigación y aplicaciones.

Gunning. (2018). *Explainable Artificial Intelligence (XAI)*. Retrieved from https://www.darpa.mil/program/explainable-artificial-intelligence

Harris, S. (2018). Signify Research - Unlocking the Value of AI in Medical Imaging. Retrieved from https://www.signifyresearch.net/medical-imaging/unlocking-value-ai-medical-imaging/

Harris, S. (2018). Signify Research - AI at RSNA – Signs of Maturity, But A Long Way to Go. Retrieved from https://www.signifyresearch.net/medical-imaging/ai-rsna-signs-maturity-long-way-go/

Harris, S. (2018). AI in Medical Imaging to Top $2 Billion by 2023. Retrieved from https://www.signifyresearch.net/medical-imaging/ai-medical-imaging-top-2-billion-2023/

Harris, S. (2018). *What's new for machine learning in medical imaging - Predictions for 2019 and beyond*. Retrieved from https://s3-eu-west-2.amazonaws.com/signifyresearch/app/uploads/2018/10/16101114/Signify_AI-in-Medical-Imaging-White-Paper.pdf

Harris, S. (2019). Funding Analysis of Companies Developing Machine Learning Solutions for Medical Imaging. *Signify Research*.

Harvey, H. (2017). Medium - UK can lead in Radiology AI. Here's how…. *Towards Data Science*. Retrieved from https://medium.com/@DrHughHarvey/uk-can-lead-in-radiology-ai-heres-how-c4c98990d833

Harvey, H. (2017). Medium - How to get clinical AI tech approved by regulators. *Towards Data Science*. Retrieved from https://towardsdatascience.com/how-to-get-clinical-ai-tech-approved-by-regulators-fa16dfa1983b

Hastings, C. (2017). *Voxel Cloud Automated Medical Image Analysis: Interview with Xiaowei Ding, CEO of Voxel Cloud*. Retrieved from https://www.medgadget.com/2017/06/voxelcloud-automated-medical-image-analysis-interview-xiaowei-ding-ceo-voxelcloud.html

Haus, A. G., & Cullinan, J. E. (2013). Screen film processing systems for medical radiography: a historical review. *RadioGraphics*, *9*(6), 1203–1224. https://doi.org/10.1148/radiographics.9.6.2685941

HiperTextual. (2016). El papel de la cuarta revolución industrial en la economía mundial. Retrieved from https://hipertextual.com/presentado-por/dell-emc/cuarta-revolucion-industrial-dell

Huynh, N. (2019). How the “Big 4” Tech Companies Are Leading Healthcare Innovation. *Healthcare Weekly*. Retrieved from https://healthcareweekly.com/how-the-big-4-tech-companies-are-leading-healthcare-innovation/

IBM. (2018). IBM Watson Imaging Patient Synopsis.

IBM. (2016). Imagine your world with Watson. Treatment and differential diagnosis insights for the physician’s consideration in the moments that matter most, 8. Retrieved from https://www.ibm.com/blogs/watson-health/wp-content/uploads/2016/12/WHI-Overview-Executive-Brief.pdf

Insider, B. (2018). How Microsoft’s top scientists have built a big business in hacking healthcare — and helped a lot of people along the way. Retrieved from https://www.businessinsider.com/peter-lee-microsoft-research-healthcare-next-interview-2018-2

Insights, C. (2019). Apple Is Going After The Healthcare Industry, Starting With Personal Health Data. Retrieved from https://www.cbinsights.com/research/apple-healthcare-strategy-apps/

Jindal, P. (2019). How Microsoft, Google, Apple, and Amazon are Fueling FHIR. *Arena Solutions*. Retrieved from https://www.darenasolutions.com/blog/how-microsoft-google-apple-and-amazon-are-fueling-fhir

José Ramirez. (2009). Telemedicina y teleradiología. Retrieved from http://cardonelectiva.blogspot.com/2009/04/telemedicina-y-teleradiologia.html

Kaminski, M. E. (2018). The Right to Explanation, Explained. *SSRN Electronic Journal*, (18). https://doi.org/10.2139/ssrn.3196985

Keynes, J. M. (1930). Economic Possibilities for our Grandchildren. *Revisiting Keynes*, 17–26. https://doi.org/10.7551/mitpress/9780262162494.003.0002

Kim, E. (2018). Inside Amazon’s Grand Challenge — a secretive lab working on cancer research and other ventures. Retrieved from https://www.cnbc.com/2018/06/05/amazon-grand-challenge-moonshot-lab-google-glass-creator-babak-parviz.html

Kos, S. (2018). Mejores resultados clínicos gracias a la Inteligencia Artificial. Retrieved from http://www.interempresas.net/TIC/Articulos/223147-Mejores-resultados-clinicos-gracias-a-la-Inteligencia-Artificial.html

Krupinski. (2013). Teleradiology: current perspectives. Retrieved from https://www.dovepress.com/teleradiology-current-perspectives-peer-reviewed-fulltext-article-RMI

Kyle Wiggers. (2018). VB - DiA Imaging Analysis raises $5 million for AI that analyzes ultrasound scans. Retrieved from https://venturebeat.com/2018/08/06/dia-imaging-analysis-raises-5-million-for-ai-that-analyzes-ultrasound-scans/

Lance Smith. (2017). Is Your Data Hot Or Not? Retrieved from https://www.forbes.com/sites/forbestechcouncil/2017/06/16/is-your-data-hot-or-not/#f69aa70449eb

Langlotz, C. P. (2019). Will Artificial Intelligence Replace Radiologists? *Radiology: Artificial Intelligence*, *1*(3), e190058. https://doi.org/10.1148/ryai.2019190058

Leonardi, F. (2018). The Definition of Health: Towards New Perspectives, 1–14. https://doi.org/10.1177/0020731418782653

Licking, E., Evans, J., & Bean, A. (2018). When the human body is the biggest data platform, who will capture value? Progressions 2018. Retrieved from https://www.ey.com/en_gl/digital/when-the-human-body-is-the-biggest-data-platform-who-will-capture-value

Lindsey, R., Daluiski, A., Chopra, S., Lachapelle, A., Mozer, M., Sicular, S., … Potter, H. (2018). Deep neural network improves fracture detection by clinicians. Proceedings of the National Academy of Sciences, 115(45), 11591–11596. https://doi.org/10.1073/pnas.1806905115

Liu, K., Li, Q., Ma, J., Zhou, Z., Sun, M., Deng, Y., … Liu, S. (2019). Evaluating a Fully Automated Pulmonary Nodule Detection Approach and Its Impact on Radiologist Performance. *Radiology: Artificial Intelligence*, *1*(3), e180084. https://doi.org/10.1148/ryai.2019180084

Lopez Briega, R. (2016). Redes neuronales convolucionales con TensorFlow. Retrieved from https://relopezbriega.github.io/blog/2016/08/02/redes-neuronales-convolucionales-con-tensorflow/

Lugo-Fagundo, C., Vogelstein, B., Yuille, A., & Fishman, E. K. (2018). Deep Learning in Radiology: Now the Real Work Begins. *Journal of the American College of Radiology*, *15*(2), 364–367. https://doi.org/10.1016/j.jacr.2017.08.007

Lunden, I. (2017). Apple acquires AI company Lattice Data, a specialist in unstructured 'dark data', for $200M. *TechCrunch*. Retrieved from https://techcrunch.com/2017/05/13/apple-acquires-ai-company-lattice-data-a-specialist-in-unstructured-dark-data/

Madrid, G. (2013). Iniciativas de Evaluación y Coste Efectividad en Radiología, *14*(3), 359–361.

Malin, B. (2012). Guidance Regarding Methods for De-identification of Protected Health Information in Accordance with the Health Insurance Portability and Accountability Act (HIPAA) Privacy Rule. *The Office for Civil Rights (OCR)*, 1–32. Retrieved from http://www.hhs.gov/ocr/privacy/hipaa/understanding/coveredentities/De-identification/hhs_deid_guidance.pdf%5Cnhttp://www.hhs.gov/ocr/privacy/hipaa/understanding/coveredentities/De-identification/guidance.html#standard

Max Tegmark. (2017). Vida 3.0.

Mazurowski, M. A., Buda, M., Saha, A., & Bashir, M. R. (2018). Deep learning in radiology: An overview of the concepts and a survey of the state of the art with focus on MRI. *Journal of Magnetic Resonance Imaging*, *49*(4), 939–954. https://doi.org/10.1002/jmri.26534

McBee, M. P., Awan, O. A., Colucci, A. T., Ghobadi, C. W., Kadom, N., Kansagra, A. P., … Auffermann, W. F. (2018). Deep Learning in Radiology. *Academic Radiology*, *25*(11), 1472–1480. https://doi.org/10.1016/j.acra.2018.02.018

McCarthy, J. (2007). What is artificial intelligence?

McGuire, B., Smith, C., Huang, T., & Yang, G. (2006). The History of Artificial Intelligence, (December), 1–27.

Microsoft. (2018). Machine Learning and the Inner Eye for Cancer Treatment with Dr. Antonio Criminis. Retrieved from https://www.microsoft.com/en-us/research/blog/machine-learning-and-the-innereye-for-cancer-treatment-with-dr-antonio-criminisi/

Microsoft. (2019). Democratizing AI in Health. Retrieved from http://democratizing-ai-in-health.azurewebsites.net/index.html

Middleton, C. (2018). Healthtech: Facebook developing AI to make MRI scans 10 times faster. *Internet of Business*. Retrieved from https://internetofbusiness.com/facebook-nyu-developing-ai-to-make-mri-10-times-faster/

Munford. (2017). Zebra takes healthcare to the next level. *Forbes*. Retrieved from https://www.forbes.com/sites/montymunford/2017/10/27/zebra-takes-healthcare-to-next-level-with-1-image-scans/#214ec8b2543d

Nanterme, P. (2016). Digital disruption has only just begun. *World Economic Forum*.

United Nations. (2017). Envejecimiento. Retrieved from https://www.un.org/es/sections/issues-depth/ageing/index.html

News, H. C. I. (2017). Combination of PACS and AI helps uncover what radiologists sometimes miss. Retrieved from https://www.healthcareitnews.com/news/combination-pacs-and-ai-helps-uncover-what-radiologists-sometimes-miss

Ng, A. (2019). How to Choose Your First AI Project. *Harvard Business Review*. Retrieved from https://hbr.org/2019/02/how-to-choose-your-first-ai-project

NIH. (2019). Tomografía. National Institute of Biomedical Imaging and Bioengineering. Retrieved from https://www.nibib.nih.gov/espanol/temas-cientificos/tomografía-computarizada-tc

NIH. (2019). Ultrasonido. In *National Institute of Biomedical Imaging and Bioengineering*. Retrieved from https://www.nibib.nih.gov/espanol/temas-cientificos/ultrasonido#pid-1971

NIH. (2019). Resonador Magnético. In *National Institute of Biomedical Imaging and Bioengineering*.

O'Shea, K., & Nash, R. (2015). An Introduction to Convolutional Neural Networks, (December). Retrieved from http://arxiv.org/abs/1511.08458

Oakden-Rayner, L. (2019). The Rebirth of CAD: How Is Modern AI Different from the CAD We Know? *Radiology: Artificial Intelligence*, *1*(3), e180089. https://doi.org/10.1148/ryai.2019180089

Ohta, Y., Yunaga, H., Kitao, S., Fukuda, T., & Ogawa, T. (2019). Detection and Classification of Myocardial Delayed Enhancement Patterns on MR Images with Deep Neural Networks: A Feasibility Study. *Radiology: Artificial Intelligence*, *1*(3), e180061. https://doi.org/10.1148/ryai.2019180061

OMS. (2019). Definición de Salud. Retrieved from https://www.who.int/es/about/who-we-are/frequently-asked-questions

OMS (2018). Cáncer. Retrieved from https://www.who.int/es/news-room/fact-sheets/detail/cancer

Orozco, G. (1996). *La investigación en comunicación desde la perspectiva cualitativa. U.N.L.P., La Plata, Argentina.*

Ovanesso, A., & Plastino, E. (2017). Como la Inteligencia Artificial Generar Crecimiento en Sudamérica, 30.

Pascual, D. (2018). Inteligencia Artificial: Un panorama de algunos de sus desafíos éticos y jurídicos.

Perasso, V. (2016). Qué es la cuarta revolución industrial (y por qué debería preocuparnos). *BBC News*. Retrieved from https://www.bbc.com/mundo/noticias-37631834

Péré-laperne, J. (2017). Restructuring Unstructured Documents On the use of smart and semi-automatic interfaces to structure unstructured data, (IDC), 60–65.

Pesapane, F., Volonté, C., Codari, M., & Sardanelli, F. (2018). Artificial intelligence as a medical device in radiology: ethical and regulatory issues in Europe and the United States. *Insights into Imaging*, *9*(5), 745–753. https://doi.org/10.1007/s13244-018-0645-y

Porter, K. (2019). The Top Acquires in Artificial Intelligence And Select Emerging Growth Companies. *Woodside Capital Partners*, (February).

Press, G. (2919). AI Startup Zebra Medical Vision Enlists Deep Learning to Save Lives. *Forbes*. Retrieved from https://www.forbes.com/sites/gilpress/2019/04/22/ai-startup-zebra-medical-vision-enlists-deep-learning-to-save-lives/#409cb7ec1035

PWC. (2017). What doctor? (June), 1–50. Retrieved from http://medicalfuturist.com/

PWC. (2018). The macroeconomic impact of AI, (February), 1–75. Retrieved from www.pwc.com

RadiologyInfo.org. (2019). Profesiones en radiología diagnóstica. Retrieved from https://www.radiologyinfo.org/sp/info.cfm?pg=professions-diagnostic-radiology#parte_seis

Rao, A. S., & Verweij, G. (2017). Sizing the prize. *PwC*, 32. Retrieved from https://www.pwc.com/gx/en/issues/analytics/assets/pwc-ai-analysis-sizing-the-prize-report.pdf

Ray, S. (2018). History of AI. Retrieved from https://towardsdatascience.com/history-of-ai-484a86fc16ef

Roach, J. (2016). Microsoft researchers detect lung-cancer risks in web search logs. Retrieved from https://blogs.microsoft.com/ai/microsoft-researchers-detect-lung-cancer-risks-web-search-logs/

Rogers, A. (2019). The 80% Blind Spot: Are You Ignoring Unstructured Organizational Data? *Forbes*. Retrieved from https://www.forbes.com/sites/forbestechcouncil/2019/01/29/the-80-blind-spot-are-you-ignoring-unstructured-organizational-data/#4cbb0224211c

Romero, J. J. (2007). *Inteligencia Artificial y Computación Avanzada*. (F. A. Brañas, Ed.).

Rosenkrantz, A. B., Hughes, D. R., & Duszak, R. (2015). The U.S. Radiologist Workforce: An Analysis of Temporal and Geographic Variation by Using Large National Datasets. *Radiology*, *279*(1), 175–184. https://doi.org/10.1148/radiol.2015150921

Russell, S. P. N. (1994). *Artificial Intelligence - A modern approach*. https://doi.org/10.1017/S0269888900007724

Rutering, J., Ilmer, M., Recio, A., Coleman, M., Vykoukal, J., Alt, E., & Orleans, N. (2016). Artificial intelligence in radiology Ahmed, *5*(6), 1–8. https://doi.org/10.4172/2157-7633.1000305.Improved

Sahiner, B., Pezeshk, A., & Petrick, N. (2018). *An update on FDA perspectives for machine learning in medical image interpretation*. Retrieved from https://cdn.ymaws.com/siim.org/resource/resmgr/mimi18/presentations/18cmimi-sahiner.pdf

Sampierí, R. H. (2006). Metodología de la Investigación (pp. 57–68). Retrieved from https://idolotec.files.wordpress.com/2012/04/sampieri-cap-4.pdf

Sarraf, S., DeSouza, D. D., Anderson, J., & Tofighi, G. (2017). DeepAD: Alzheimer's Disease Classification via Deep Convolutional Neural Networks using MRI and fMRI. *BioRxiv*, (August 2016), 1–32. https://doi.org/10.1101/070441

Sayres, R. (2018). Improving the Effectiveness of Diabetic Retinopathy Models. *Google AI Blog*. Retrieved from https://ai.googleblog.com/2018/12/improving-effectiveness-of-diabetic.html

Schwab, K. (2017). The fourth industrial revolution. Currency.

Schwab, K., Chairman, E., & Forum, W. E. (2016). The Fourth Industrial Revolution: what it means, how to respond.

Selanikio, J. (2018). The Shaming of Watson. *Medium - Blog - Becoming Human*. Retrieved from https://becominghuman.ai/the-shaming-of-watson-3d0672d59f1

Seyed Ameli Renani, & Belli, A.-M. (2014). A career in interventional radiology. *TheBMJ*. Retrieved from https://www.bmj.com/content/349/bmj.g5040

Shaan Ray. (2018). History of AI. Retrieved from https://towardsdatascience.com/history-of-ai-484a86fc16ef

Shankland, S. (2019). Google working to fix AI bias problems. Retrieved from https://www.cnet.com/news/google-working-to-fix-ai-bias-problems/

Shead, S. (2017). The VC arm of Google's parent company is betting its billions on life-enhancing healthcare startups. *Business Insider*. Retrieved from https://www.businessinsider.com/gv-alphabet-vc-arm-pouring-billions-health-startups-life-expectancy2017-8

Sheps, S. G. (2016). Ecografía Doppler: ¿Para qué se usa? Retrieved from https://www.mayoclinic.org/es-es/doppler-ultrasound/expert-answers/faq-20058452

Sicular, S., & Brant, K. (2018). Hype Cycle for Artificial Intelligence. *Gartner*, (Juli), 5–6, 45–47. Retrieved from http://k1.caict.ac.cn/yjts/qqzkgz/zksl/201808/P020180814355000666438.pdf

SilvaIII, E. (2013). ACR White Paper on Teleradiology Practice: A Report From the Task Force on Teleradiology Practice. *JACR*, *10*(8), 575–585. https://doi.org/10.1016/j.jacr.2013.03.018

Spanu, A. (2018). Amazon's new Alexa will know someone is sick by listening to their voice. *Healthcare Weekly,* Retrieved from https://healthcareweekly.com/amazon-alexa/

Stenman, M. (2015). *Automatic speech recognition: An evaluation of Google Speech*.

Stumpe, M. (2017). Assisting Pathologists in Detecting Cancer with Deep Learning. Retrieved from https://ai.googleblog.com/2017/03/assisting-pathologists-in-detecting.html

Susskind, R., & Susskind, D. (2016). Technology Will Replace Many Doctors, Lawyers, and Other Professionals. *Harvard Business Review*. Retrieved from https://hbr.org/2016/10/robots-will-replace-doctors-lawyers-and-other-professionals

Szeliski, R. (2010). *Computer Vision: Algorithms and Applications*.

TechinAsia. (2017). Voxel Cloud - This Tencent-backed startup wants to use AI to solve disparities in China's healthcare. Retrieved from https://www.techinasia.com/voxelcloud-profile

The Economist. (2018). VIZ - Artificial intelligence will improve medical treatments. Retrieved from https://www.economist.com/science-and-technology/2018/06/07/artificial-intelligence-will-improve-medical-treatments?frsc=dg%7Ce

The Medical Futurist. (2018). Google's Masterplan for Healthcare. Retrieved from https://medicalfuturist.com/googles-masterplan-for-healthcare

The Medical Futurist. (2018). 5 Reasons Why A.I. Will Not Replace Physicians. Retrieved from https://www.youtube.com/watch?v=a1QguDFMBM8

The Royal Society. (2017). *Machine learning: the power and promise of computers that learn by example*. *Report by the Royal Society* (Vol. 66). https://doi.org/10.1126/scitranslmed.3002564

Thrall, J. H., Li, X., Li, Q., Cruz, C., Do, S., Dreyer, K., & Brink, J. (2018). Artificial Intelligence and Machine Learning in Radiology: Opportunities, Challenges, Pitfalls, and Criteria for Success. *Journal of the American College of Radiology*, *15*(3), 504–508. https://doi.org/10.1016/j.jacr.2017.12.026

Thurston, M., & Bell, D. J. (2019). Modality. Retrieved from https://radiopaedia.org/articles/modality

Vayena, E., Blasimme, A., & Cohen, I. G. (2018). Machine learning in medicine: Addressing ethical challenges. *PLOS Medicine*, *15*(11), e1002689. https://doi.org/10.1371/journal.pmed.1002689

Velasco, G. de la calle. (2014). *Modelo basado en técnicas de procesamiento de lenguaje natural para extraer y anotar información de publicaciones científicas*.

Vignolo, J. (2011). Levels of care, prevention and primary health care, (1), 11–14.

Vilares Ferro. (2005). *Aplicaciones del procesamiento del lenguaje natural en la recuperación de la información en español*.

Wallis, A., & Mccoubrie, P. (2011). The radiology report d Are we getting the message across? *Clinical Radiology*, *66*(11), 1015–1022. https://doi.org/10.1016/j.crad.2011.05.013

Wang, J. (2016). ARK Invest - Deep Learning Based Diagnostics: Unlocking a $16 Billion Market. Retrieved from https://ark-invest.com/research/deep-learning-based-diagnostics

Wang, Y., Kung, L. A., & Byrd, T. A. (2018). Big data analytics: Understanding its capabilities and potential benefits for healthcare organizations. *Technological Forecasting and Social Change*, *126*, 3–13. https://doi.org/10.1016/j.techfore.2015.12.019

Wikipedia. (2019). Inteligencia. Retrieved from https://es.wikipedia.org/wiki/Inteligencia

Wikipedia. (2019). Historia de la Inteligencia Artificial. Retrieved from https://es.wikipedia.org/wiki/Historia_de_la_inteligencia_artificial

Yasaka, K., & Abe, O. (2018). Deep learning and artificial intelligence in radiology: Current applications and future directions. *PLOS Medicine*, *15*(11), e1002707. https://doi.org/10.1371/journal.pmed.1002707

Zikopoulos, P. (2016). Understanding big data. *CIM Magazine*, *11*(1). https://doi.org/10987654321

Universidad de SanAndrés

ANEXOS

ANEXO A - Entrevistas realizadas

Facundo Manes

- Médico neurólogo, Universidad de Buenos Aires (UBA).
- Doctorado en Ciencias, Universidad de Cambridge.
- Creador del Instituto de Neurología Cognitiva (INECO).
- Presidente de la Fundación INECO.
- Ex rector de la Universidad Favaloro.
- Divulgador científico.

Ricardo García Mónaco

- Médico especialista en DPI, UBA.
- Especialista en terapia endovascular y angiografía.
- Jefe del Servicio de Diagnóstico por Imágenes del Hospital Italiano de Buenos Aires.
- Presidente de la Sociedad Argentina de Radiología, entre el 2001 y el 2006.
- Profesor Titular en la Especialidad de Diagnóstico por Imágenes de la Facultad de Medicina de la UBA.

Daniel Luna

- Médico especialista en medicina interna, UBA.
- Jefe del departamento de Informática Médica del Hospital Italiano de Buenos Aires.
- Master en Ingeniería de Sistemas de Información, Universidad Tecnológica Nacional (UTN).

- Doctor en Ingeniería Informática, Instituto Tecnológico Buenos Aires (ITBA).
- Profesor titular de Informática Médica, Instituto Universitario Hospital Italiano y CEMIC.
- Co director de la maestría y la residencia de Informática en Salud del Instituto Universitario Hospital Italiano de Buenos Aires.

Federico Milano

- Ingeniero en Sistemas de Información, UTN.
- Doctor en Informática, ITBA.
- Especialista en procesamiento de imágenes médicas y cirugías asistidas por computadora.

Hernán Borré

- Ingeniero en Sistemas de Información, Universidad Tecnológica Nacional (UTN).
- Maestría en Inteligencia Artificial, Universidad de Essex, Inglaterra.

Tomás Crivelli

- Ingeniero en electrónica, UBA.
- Doctor en Inteligencia Artificial, Universidad de Rennes I, Francia.
- CTO de la empreza de IA, ZowlLabs.

Dr. Diego Slezak

- Licenciado en Ciencias de la Computación, UBA.
- Doctor en Ciencias de la Computación, UBA.
- Investigador del Instituto ICC (CONICET) y profesor en la Facultad de Ciencias Exactas y Naturales de la UBA.
- Fundador & CTO de Entelai.

Ing. Carlos Selmo

- Ingeniero Electrónico, ITBA.
- Doctorando en Inteligencia Artificial, ITBA.
- Profesor adjunto de materias en el área de procesamiento de señales, bio-electrónica y sistemas digitales. Entre ellas Redes Neuronales y Redes Neuronales en Bioingeniería, ITBA.

Gustavo Pantol

- Medico especialista en Diagnóstico por Imágenes, Universidad de Cuyo.
- Especialista en Diagnóstico por Imágenes, Mount Sinai Medical Center, Estados Unidos.
- Subespecialista en neuroimágenes, Universidad de Harvard.

Enzo Ferrante

- Ingeniero en Sistemas de Información, Universidad Nacional del Centro de Buenos Aires (UNICEN).
- Doctor en Ciencias de la Computación, Universidad París-Saclay, Francia.
- Posdoctorado en Deep Learning y segmentación de imágenes de cerebro, Imperial College London, Inglaterra.
- Investigador CONICET/Universidad del Litoral en Métodos Computacionales para en análisis de imágenes biomédicas.

ANEXO B – Preguntas utilizadas en las entrevistas

A continuación, se detallan las preguntas utilizadas como directriz para conducir las entrevistas realizadas. Según el perfil del entrevistado se agregaron u omitieron algunas preguntas.

1. ¿Qué problemas le encuentra a ML en general y DL en particular respecto al análisis de imágenes?
2. ¿Qué limitaciones genera que los algoritmos basados en redes neuronales convolucionales sean todavía una caja negra?
3. ¿Cómo ve el tema de que empresas como Google se encuentren trabajando en que las RNC dejen de ser una caja negra?
4. ¿Qué hitos se deberían alcanzar para que las soluciones basadas en ML tomen decisiones relacionadas con la salud de las personas sin la supervisión de un profesional?
5. ¿Qué beneficios considera que tendrán los médicos especialistas en DPI en el uso de herramientas basadas en ML?
6. ¿Cómo impactará ML al rol del médico especialista en DPI tal cual se lo conoce hoy?
7. ¿Qué beneficios tendrán los pacientes en el uso de herramientas basadas en ML?
8. ¿Qué impacto tendrá la IA en la industria de la salud?
9. ¿Considera que la IA General será realidad? ¿De qué forma?

ANEXO C – Otros tipos de IA

C.1 Sistemas Expertos

Según el Grupo Especialista en Sistemas Expertos de la British Computer Society, un Sistema Experto está definido como la incorporación dentro de un sistema

informático de un componente basado en el conocimiento, correspondiente a una habilidad experta, de tal forma que el sistema pueda ofrecer asesoramiento inteligente o tomar una decisión inteligente sobre una función del proceso. Una característica adicional deseable, que muchos consideran fundamental, es la capacidad del sistema, si se le solicita, de justificar su propia línea de razonamiento de un modo directamente inteligible para el interrogador. El estilo adoptado para alcanzar estas características es la programación basada en reglas (Forsyth, 1984).

El objetivo es resolver problemas de un campo específico del conocimiento humano de manera tal de exhibir tanta destreza como un humano experto resolviendo esa misma tarea (Batarekh, Preece, Bennett, & Grogono, 1991).

Las características de un sistema experto son las siguientes:

- Base de conocimiento: contiene hechos y reglas. Los hechos son información a corto plazo que puede ser modificada rápidamente. Las reglas son información a largo plazo acerca de cómo generar nuevos hechos o hipótesis a partir de lo que se conoce actualmente.
- Motor de inferencia: hay dos formas principales de llegar al conocimiento, el "*forward chaining*" y el "*backward changing*". El "*forward chaning*" implica el razonamiento desde los datos hasta las hipótesis, mientras que el "*backward chaning*" intenta encontrar datos para probar o refutar una hipótesis. El "*forward changing*" puro lleva a un cuestionamiento desenfocado en un sistema de modo de diálogo, mientras que el "*backward chaning*" puro tiende a ser bastante implacable en su interrogatorio dirigido a objetivos. Por lo tanto, los sistemas más exitosos utilizan una combinación de ambos.
- Estrategias de inducción: se define cómo se va a obtener el conocimiento. La forma tradicional era reunir un experto de un dominio específico con un ingeniero de conocimiento, juntos negocian efectivamente una versión

codificada de lo que el experto sabe. Dado que este proceso es costoso y lleva mucho tiempo, existen sistemas enfocados a esta tarea.

- La interfaz de usuario: todo sistema experto debe tener una buena interfaz de usuario. Un razonamiento del sistema experto que no pueda ser explicado a una persona en forma correcta no es de utilizada, incluso si "funciona" mejor que un humano experto (Richard Forsyth, 1984).

C.2 Procesamiento de Lenguaje Natural

El PLN es la rama de la IA encargada del tratamiento del lenguaje natural, entendido como el lenguaje humano. El mismo se contrapone al lenguaje formal, propio del ámbito lógico, matemático y computacional. El objetivo del PLN es dotar a la computadora de la capacidad de comprender el lenguaje humano. También podemos clasificar su objetivo en:

- **Procesamiento de textos**: la mayor parte de la información existente está expresada en escritos. Esto se potencia con el desarrollo de las tecnologías de la información, ampliándose cada vez más las bases de datos de conocimiento.
- **Traducción automática:** en la actualidad se pueden encontrar muchos sitios web y aplicaciones que traducen textos de un lenguaje a otro. Cada uno de estos posee un propio método de traducción de texto (basados en reglas, en estadísticas, en contexto, en ejemplos, por citar algunos). Si bien todavía queda un recorrido para que estos sistemas funcionen a la perfección, en el último tiempo han mejorado significativamente.
- **Interfaces en lenguaje natural:** desarrollo de interfaces que permitan, a través de texto o de lenguaje natural, expresar órdenes. Las mismas deben ser comprendidas por la computadora y ejecutadas (Velasco, 2014).

Por otra parte, son cuatro niveles de conocimiento que debe poseer un sistema de PLN para comprender el lenguaje humano:

- Conocimiento morfológico: su finalidad es conocer las palabras del lenguaje.
- Conocimiento sintáctico: el mismo permite comprender cómo se combinan las palabras, formando así las frases.
- Conocimiento semántico: determina el significado de cada palabra.
- Conocimiento pragmático: permite distinguir la relación entre el lenguaje y el contexto en el que es utilizado (Vilares Ferro, 2005).

C.3 Reconocimiento de voz

El concepto reconocimiento de voz - o *speech recognition* - hace referencia a aquellos sistemas que tienen el objetivo de establecer una comunicación entre el hombre y la computadora a través del habla.

Las condiciones de evaluación y exactitud pueden variar por diferentes características:

- **Tamaño del vocabulario y palabras confusas.** Con un vocabulario acotado es más sencillo reconocer palabras. La probabilidad de error de estos sistemas se incrementa con el tamaño del vocabulario que debe manejar.
- **Dependencia/Independencia del locutor.** Los sistemas pueden clasificarse según su dependencia o independencia del locutor. Los sistemas dependientes poseen un proceso de entrenamiento, a través de un único locutor. Esto reduce significativamente la probabilidad de error. Existen también los sistemas que se adaptan al locutor, estos aprenden a comprender cualquier voz dada un pequeño entrenamiento.
- **Discurso aislado, discontinuo o continuo**. Aislado hace referencia a sistemas que reconocen de a una palabra. Los discontinuos, por otra parte, reconocen oraciones enteras, siempre que se haga una pausa entre cada palabra. Por último, el discurso continuo es el que reconoce el habla de manera natural, sin pausas ni otra herramienta que lo haga particularmente más comprensible.

- **Restricciones del lenguaje**. Las restricciones están dadas por la gramática, la cual establece reglas para el lenguaje. A través de las mismas, los sistemas son capaces de filtrar oraciones irrazonables (Stenman, 2015).

C.4 Robótica

La robótica puede definirse desde diferentes ángulos. Sociológicamente es “todo aquello capaz de sustituir al ser humano en la realización de las tareas que éste ejecuta, o de llevar a cabo tareas para las cuales aquél es incapaz, mediante procesos mecanizados y programados, y que se integra en los procesos productivos de una sociedad, pudiendo incluso interactuar con los miembros de ésta” (Pascual, 2018).

Científicamente, puede definirse como “la ciencia que estudia el diseño y construcción de máquinas capaces de desempeñar las tareas mencionadas”.

Las máquinas o robots dotados de IA son “aquellos sistemas mecánicos que perciben el ambiente externo por sí mismo sin necesidad de órdenes preprogramadas externas, con capacidad de captar y percibir diferentes circunstancias que sucedan en su entorno y con capacidad para desplazarse voluntariamente. Los sistemas de IA deben de obedecer tanto órdenes de otros sistemas de IA como las órdenes de los humanos que interaccionan con él”.

Se entiende que el robot no es una IA en sí misma, sino que representa el soporte físico o periférico que hace de interfaz con el ambiente. Su IA está basada en el software que determina su comportamiento (Pascual, 2018).